



MODELO DE SÉRIES TEMPORAIS DE PRECIPITAÇÃO PARA A CIDADE DE CHIMOIO-MOÇAMBIQUE

Precipitation time series model for the city of Chimoio-Mozambique

Modelo de series temporales de precipitación para la ciudad de Chimoio, Mozambique

Jone Chacuinda Sumbulero  

Universidade Federal de Lavras (UFLA)

jonechacuinda@gmail.com

Noé Osório Macário  

Universidade Federal de Lavras (UFLA)

omacario90@gmail.com

Luiz Otávio de Oliveira Pala  

Universidade Federal de Lavras (UFLA)

luispala@ufla.br

Luiz Fernando Coutinho de Oliveira  

Universidade Federal de Lavras (UFLA)

coutinho@ufla.br

Thelma Sáfadi  

Universidade Federal de Lavras (UFLA)

safadi@ufla.br

Paulo Henrique Sales Guimarães  

Universidade Federal de Lavras (UFLA)

paulo.guimaraes@ufla.br

Resumo: Desde 1970, o mundo tem observado um aumento na temperatura e uma intensificação no ciclo hidrológico, o que resulta em maior quantidade de vapor d'água na atmosfera e torna a disponibilidade de água menos previsível e mais variável. A identificação de alterações nos registros

meteorológicos é de grande importância para simulações hidrológicas pelo uso de modelos estocásticos com o foco na predição e preparação da sociedade para os impactos provocados por possíveis eventos extremos ou raros. Assim, este trabalho teve como objetivo estudar a variabilidade temporal da precipitação pluviométrica mensal na cidade de Chimoio, ajustando um modelo de séries temporais para o período de 1989 a 2022. A metodologia empregada consistiu em analisar a variabilidade mensal da precipitação por meio do coeficiente de variação e da tendência, sendo que o ajuste do modelo de séries temporais de precipitação foi baseado no método proposto por Box e Jenkins (1976). Os resultados indicaram uma relação entre o fenômeno El Niño-Oscilação Sul (ENOS) e a variabilidade da precipitação, com maior variabilidade a ser encontrada nos meses de novembro, dezembro, janeiro e fevereiro. Em termos anuais, o ano 2008 mostrou a maior variabilidade. A análise de tendência revelou significância estatística para o mês de agosto, sendo que ela tornou-se significativa a partir de 1994. O modelo SARIMA $(7,0,1)(0,1,1)_{12}$ foi selecionado para prever observações futuras, toda as previsões feitas para o ano de 2022 estiveram dentro do intervalo de confiança de 95% estabelecido pelo modelo, mesmo considerando imprevistos e incertezas associadas a fatores climáticos.

Palavras-chave: Climatologia; Modelos SARIMA; Variabilidade

Abstract: Since 1970, the world has been witnessing an increase in temperature and an intensification of the hydrological cycle, resulting in a greater amount of water vapour in the atmosphere and making water availability less predictable and more variable. The Identification of meteorological changes in records is very important for hydrological simulations using stochastic models, in focus on prediction and preparing the society for possible extreme or rare events impacts, Thus, this study aimed to analyse the temporal monthly rainfall variability in Chimoio city by adjusting a time series model for the period from 1989 to 2022. The methodology applied is the analyse of monthly variability of precipitation using the coefficient of variation and trend analysis, with the adjustment of the time series precipitation model based on the method proposed by Box and Jenkins (1976). The results indicated a relationship between the El Niño-Southern Oscillation (ENSO) phenomenon and precipitation variability, with higher variability in the months of November, December, January, and February. Annually, the year 2008 showed the greatest variability. The trend analysis revealed statistical significance for the month of August, becoming significant from 1994 onwards. The SARIMA $(7,0,1)(0,1,1)_{12}$ model was selected to forecast future observations, with all predictions for the year 2022 falling within the 95% confidence interval established by the model, despite unforeseen events and uncertainties associated with climatic factors.

Keywords: Climatology; SARIMA models; Variability

Resumen: Desde 1970, el mundo ha observado un aumento en la temperatura y una intensificación del ciclo hidrológico, lo que resulta en una mayor cantidad de vapor de agua en la atmósfera y hace que la disponibilidad de agua sea menos predecible y más variable. La identificación de cambios en los registros meteorológicos es de gran importancia para las simulaciones hidrológicas mediante el uso de modelos estocásticos, con el objetivo de predecir y preparar a la sociedad para los impactos de posibles eventos extremos o raros. Así, este trabajo tuvo como objetivo estudiar la variabilidad temporal de la precipitación mensual en la ciudad de Chimoio, ajustando un modelo de series temporales para el período de 1989 a 2022. La metodología consistió en analizar la variabilidad mensual de la precipitación a través del coeficiente de variación y la tendencia. El ajuste del modelo de series temporales de precipitación se basó en el método propuesto por Box y Jenkins (1976). Los resultados indicaron una relación entre el fenómeno de El Niño-Oscilación del Sur (ENOS) y la variabilidad de la precipitación, con la mayor variabilidad registrada en los meses de noviembre, diciembre, enero y febrero. En términos anuales, el año 2008 mostró la mayor variabilidad. El análisis de tendencia reveló

significancia estadística para el mes de agosto, y dicha tendencia se volvió significativa a partir de 1994. Se seleccionó el modelo SARIMA $(7,0,1)(0,1,1)_{12}$ para predecir futuras observaciones. Todos los pronósticos realizados para el año 2022 se encontraron dentro del intervalo de confianza del 95% establecido por el modelo, incluso considerando imprevistos e incertidumbres asociadas a factores climáticos.

Palabras clave: Climatología; Modelos SARIMA; Variabilidad.

Submetido em: 25/06/2024

Aceito para publicação em: 11/07/2025

Publicado em: 16/09/2025

1. INTRODUÇÃO

As mudanças climáticas são uma resposta da dinâmica do sistema terra a fatores intrínsecos ou extrínsecos ao planeta (Brito et al., 2022).

As transformações ambientais do presente estão intrinsecamente associadas à atividade humana, em especial pela elevação dos níveis de gases de efeito estufa, o que acelera os processos relacionados às mudanças climáticas. Esses fenômenos têm causado elevação na temperatura média global, além de gerar variações nas séries históricas de precipitação, apresentando tanto tendências de aumento quanto de redução (Jhajharia et al., 2013; Guedes; Priebe; Manke, 2019).

Desde a década de 1970, têm sido registradas elevações nas temperaturas globais e um fortalecimento do ciclo hidrológico (Seneviratne, Nicholls e Easterling, 2012), resultando em maior concentração de vapor d'água na atmosfera e, consequentemente, em uma disponibilidade hídrica mais instável e difícil de prever (Marengo et al., 2008).

Numa escala local ou regional, as mudanças climáticas são detectadas por meio de análise de tendências nas séries históricas das variáveis meteorológicas, como temperatura e precipitação (Silva Junior; Fonseca Neto; Cabral, 2020). Identificar e quantificar estas alterações é um processo complexo, dada a incerteza presente na dinâmica dos processos hidrológicos. A identificação de alterações nos registros meteorológicos é de grande importância nas simulações hidrológicas pelo uso de modelos estocásticos com o foco na predição e preparação da sociedade para os impactos provocados por possíveis eventos extremos ou raros (Ishak et al., 2013; Moreira; Naghettini, 2016).

A investigação de tendências em dados hidrológicos ao longo do tempo é de grande interesse por partes da comunidade científica, tomadores de decisões e sociedade em geral na gestão dos recursos hídricos e na mitigação de seus impactos, afetando na ocorrência de inundações, secas, geração de energia, produção de alimentos, entre outros efeitos (Santos; Aquino, 2017; Alcântara et al., 2019; Lima et al., 2021).

Nos últimos tempos, vários modelos têm sido desenvolvidos para realizar previsões e/ou monitorar a precipitação, dentre eles tem-se a classe de modelos autorregressivos integrados de médias móveis (ARIMA), algoritmos genéticos, adaptive splines threshold autoregressivo (ASTAR), K-vizinho mais próximo (KNN), dentre outros (Dimri; Ahmad; Sharif,

2020). Dentre estes, vários atores utilizaram o modelo ARIMA, por entenderem ser o mais adequado para compreender as variáveis climáticas (Kim; Hossein; Choi, 2011; Lacerda et al., 2022).

Abdul-Aziz et al. (2013) empregaram o modelo ARIMA para estudar a precipitação em Gana na região de Ashanti, os resultados indicaram mudanças significativas no padrão de precipitação ao longo do tempo. A mesma metodologia foi utilizada por Huntra e Keener (2017), no estudo de previsão da demanda de água no vale de Las Vegas e os resultados foram altamente precisos e eficazes para avaliar os efeitos das alterações climáticas. Lima et al. (2020), estudaram a variabilidade da precipitação na região sudeste do Mato Grosso, Brasil. Verificou-se que o modelo SARIMA (2,0,0) (0,1,2)₁₂ era o mais indicado para a predição de precipitações na área de estudo. Santos, Delfino e Santos (2021), adotaram o modelo SARIMA (0,0,0) (0,1,1)₁₂, para a região de Lavras, Minas Gerais e o Dimri, Ahmad e Sharif (2020) adotaram o modelo SARIMA (0,1,1)(0,1,1)₁₂; para modelar a precipitação na bacia hidrográfica de Bhagirathi situada no estado de Uttarakhand, Índia.

Apesar de Moçambique ter uma enorme potencialidade hídrica, tem sofrido grandes desafios na gestão dos recursos hídricos. Frequentemente, o país tem sofrido com as cheias e secas, afetando em especial as atividades que envolvem o setor agrícola, que é a base do desenvolvimento do país (Banco Mundial, 2014). Segundo o DFID (2006), Moçambique apresenta uma frequência anual média de 1,67 desastres naturais de grande escala, o que implica que o país enfrenta, ao menos, um evento dessa magnitude por ano. Em termos comparativos, outras nações altamente impactadas incluem Bangladesh, com uma frequência de 8,07, seguido por Etiópia (2,8), Sudão (2,15), Tanzânia (2,23) e Mali (1,77), demonstrando maior recorrência de desastres naturais severos.

De acordo com Macie e Freitas (2016), diversos fatores atmosféricos influenciam o regime de precipitação em Moçambique, tais como os ciclones tropicais originados na bacia sudoeste do Oceano Índico no verão, a Zona de Convergência Intertropical (ZCIT), frentes frias, sistemas de baixa pressão continentais, a monção india, o fenômeno El Niño/Oscilação Sul, além dos anticiclones dos oceanos Atlântico e Índico.

Em Moçambique, a rede de monitoramento hidroclimático é escassa e as medições são realizadas pelo Instituto Nacional de Meteorologia (INAM), na maioria dos casos nas capitais provinciais. Até então, foram produzidas séries temporais consideráveis que

poderiam ser utilizadas em estudos que serviram de suporte para a gestão eficiente de recursos hídricos (Macie; Freitas, 2016).

Neste contexto, o presente trabalho tem como objetivo estudar a variabilidade temporal da precipitação pluviométrica mensal da cidade de Chimoio, pelo ajuste do modelo de séries temporais, no período compreendido entre 1989-2022, a fim de obter um modelo estatístico que permita realizar previsões de precipitações.

2. METODOLOGIA

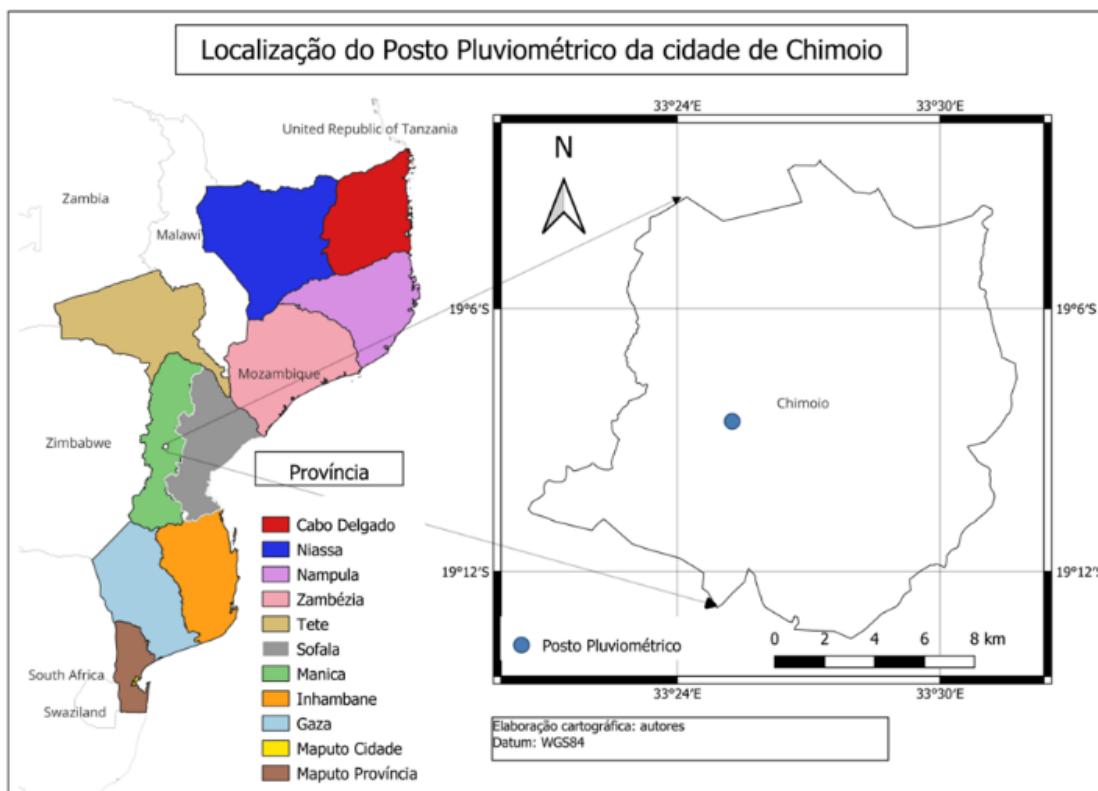
2.1. Caracterização da Área de Estudo

A cidade de Chimoio (Figura 1) está localizada na região centro de Moçambique, na província de Manica, entre as coordenadas geográficas $33^{\circ}20'32''$ a $33^{\circ}31'44''$ de longitude E e entre $19^{\circ}02'27''$ a $19^{\circ}13'28''$ de Latitude S, comprehende uma área de 241 km^2 . A altitude média da cidade é de 659,70 m, variando entre 563 m e 773 m.

Segundo a classificação climática de *Koppen* (Climate-Date, 2024), o clima é do tipo subtropical húmido (Cfa), com o tempo dividido em duas estações, estação chuvosa, no período de outubro a abril, e estação seca, no período de maio a setembro.

A cidade conta com um posto pluviométrico que é gerido pelo Instituto Nacional de Meteorologia (INAM) e está localizado no ponto de coordenadas $33^{\circ}27'36''\text{E}$ e $19^{\circ}6'36''\text{S}$. Por meio de banco de dados meteorológicos existente e disponibilizado pelo INAM, foi possível extrair dados de precipitação mensal no período compreendido entre os anos 1989 e 2022.

Figura 1- Mapas de localização da cidade de Chimoio.



Fonte: Elaborado pelos autores (2024).

2.2. Procedimentos Metodológicos

A variabilidade mensal dos dados de precipitação no período entre 1989 e 2022 foi avaliada pelas medidas de tendência central (média e mediana), medidas de dispersão (o intervalo interquartil, coeficiente de assimetria e Curtose), para cada mês no período em estudo, todas as variáveis foram apresentadas em um diagrama box-plot, empregando o software R.

A variabilidade mensal num dado ano foi quantificada pelo coeficiente de variação da precipitação (Equação 1):

$$CV_{PM} = \frac{1}{\bar{P}} \sqrt{\sum_{i=1}^{12} \frac{(P_i - \bar{P})^2}{12}} \quad [1]$$

Onde: P_i é a precipitação no mês i (mm) e \bar{P} a média das precipitações mensais no ano (mm).

A tendência foi analisada pelo teste não paramétrico de Mann-Kendall (MK), utilizado para avaliar tendências em séries temporais de dados ambientais e é muito utilizada em

hidrologia tanto em estudos de séries anuais precipitações extremas (Ely; Dubreuil, 2017; Xu et al., 2023; Zita, 2023), como em séries de precipitações mensal e anual (Menezes; Fernandes, 2016; Barbosa et al., 2023), permitindo a identificação e a estimativa do ponto em que determinada tendência tem início (Back, 2001).

O teste realiza uma verificação sequencial dos dados da série temporal, onde cada valor é comparado com os subsequentes. Em seguida, contabiliza-se o número de vezes em que esses valores posteriores superam o valor em análise (Guedes; Priebe; Manke, 2019).

A estatística S é obtida pela soma de todas as contagens (equação 2), em que o sinal ($P_i - P_j$) é determinado pela equação 3.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{Sgn}(P_i - P_j) \quad [2]$$

Em que,

$$\text{Sgn}(P_i - P_j) = \begin{cases} +1 & \text{se } (P_i - P_j) > 0 \\ 0 & \text{se } (P_i - P_j) = 0 \\ -1 & \text{se } (P_i - P_j) < 0 \end{cases} \quad [3]$$

Conforme Ahmad et al. (2015), um valor positivo de S indica tendência positiva na qual os dados crescem com o tempo; um valor negativo de S indica uma tendência negativa.

Quando $n \geq 10$, a estatística S tem distribuição aproximadamente normal cuja média e variância são dadas pelas equações 4 e 5 respectivamente.

$$E[S] = 0 \quad [4]$$

$$\text{Var}(S) = \frac{n(n-1)(2n+5)}{18} \quad [5]$$

O valor da estatística Z é dado pela equação 6.

$$Z = \begin{cases} \frac{S - 1}{\sqrt{\text{Var}(S)}} & S > 0 \\ 0 & S = 0 \\ \frac{S + 1}{\sqrt{\text{Var}(S)}} & S < 0 \end{cases} \quad [6]$$

A hipótese nula do teste de MK é de que não existe tendência significativa nas séries temporais analisadas. Para o nível de significância de 5% o valor crítico é 1,96.

Todas as análises de tendências foram realizadas pelo software R tendo em conta a

série parcial em cada mês entre 1989 e 2022, cujo objetivo foi de verificar a tendência mensal e a série completa com objetivo de se verificar a tendência ao longo de toda série de dados.

A identificação aproximada do início de uma possível tendência na série foi realizada por meio do teste sequencial de Mann-Kendall. Esse procedimento considera uma série P_i com N termos ($i = 1, 2, \dots, N$), o teste consiste na soma m_i da série, relativo ao valor P_i , em que os termos precedentes ($j < i$) são inferiores ao mesmo ($P_j > P_i$) (equação 7).

$$t_n = \sum_{i=1}^N m_i \quad [7]$$

Para séries com grande número de termos, ou seja, $n \geq 10$, sob a hipótese nula (H_0) de ausência de tendência apresentaram uma distribuição normal com média e variância dada pelas equações 8 e 9 respectivamente.

$$E(t_n) = \frac{n(n - 1)}{4} \quad [8]$$

$$\text{Var}(t_n) = \frac{n(n - 1)(2n + 5)}{72} \quad [9]$$

A verificação da significância da hipótese nula (H_0) foi conduzida por meio de um teste bilateral. Nesse contexto, H_0 é rejeitada quando a estatística $u(t_n)$ dada pela equação 10 atinge valores considerados elevados.

$$u(t_n) = \frac{t_n - E(t_n)}{\text{Var}(t_n)} \quad [10]$$

A equação é calculada no sentido direto da série, partindo do valor de $i=2$ até $i=N$, gerando a estatística $u(t_n)$ e no sentido inverso da série, partindo do valor de $i=N$ até $i=2$, gerando a estatística $u^*(t_n)$. A intersecção das duas curvas geradas representa o ponto aproximado de mudança de tendência, se este ocorre dentro do intervalo de confiança de 95% ou seja $-1,96 < u(t) < 1,96$.

2.3 Modelo ARIMA e SARIMA

O modelo autoregressivo de médias móveis (ARIMA) foi proposto pelo Box e Jenkins nos anos 1970 e resulta de uma combinação entre o modelo autoregressivo (AR) e de médias móveis (MA), ele é apropriado para descrever séries estacionárias e não estacionárias. Quando o modelo ARIMA contempla uma autocorrelação sazonal passa a ser modelo SARIMA.



O modelo SARIMA contém uma parte não sazonal com parâmetros (p,q,d) e uma parte sazonal com parâmetros $(P,Q,D)_S$, a estrutura do modelo é expressa consoante a equação 11.

$$\varphi(B)\phi(B^S)\Delta^d\Delta^D P_t = \theta(B)\Theta(B^S)e_t \quad [11]$$

em que: $\varphi(B) = (1 - \varphi_1B - \dots - \varphi_pB^p)$ é polinômio autorregressivo de ordem p;

$\phi(B^S) = (1 - \phi_1B^S - \dots - \phi_pB^{pS})$ é polinômio autorregressivo sazonal de ordem p;

$\Delta^d = (1 - B)^d$ é operador diferença, d é o número de diferenças necessárias para retirar a tendência da série;

$\Delta^D = (1 - B)^D$ é operador diferença sazonal, D é o número de diferenças necessárias para retirar a sazonalidade da série.

$\theta(B) = (1 - \theta_1B - \dots - \theta_qB^q)$ é polinômio de médias móveis de ordem q;

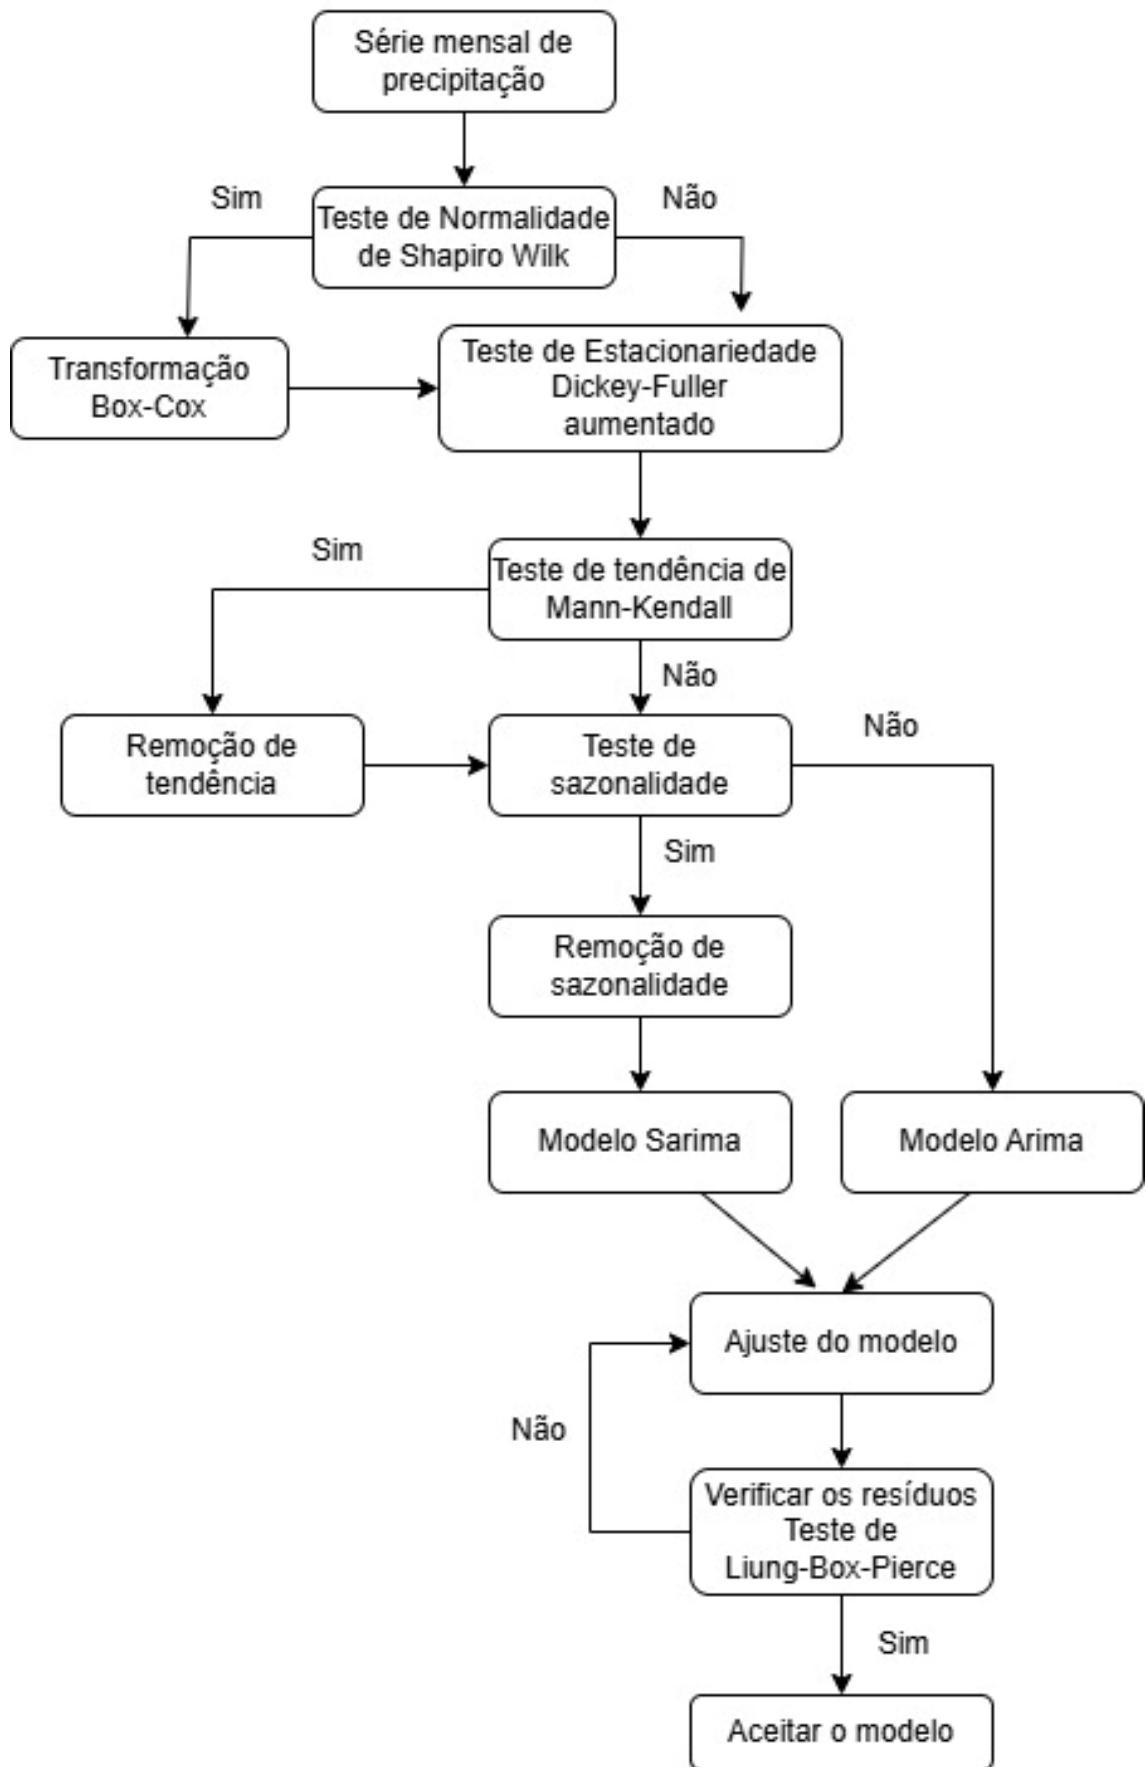
$\Theta(B^S) = (1 - \theta_1B^S - \dots - \theta_QB^{QS})$ é polinômio de médias móveis sazonal de ordem Q;

e_t é o ruído branco;

P_t é a precipitação mensal.

A metodologia empregada para o ajuste do modelo de séries temporais de precipitação baseou-se em Box e Jenkins (1976), utilizando o software R, em conformidade com o fluxograma mostrado na Figura 2:

Figura 2-Fluxograma metodológico de ajuste de modelo



Fonte: Elaborado pelos autores (2024).



Dos modelos ajustados, selecionaram-se aqueles cujo resíduo apresentou um ruído branco, e após selecionados os modelos utilizaram-se os critérios de informação de Akaike (AIC) (equação 12) e de informação Bayesiano (BIC) (equação 13) para selecionar o melhor, sendo que o escolhido foi aquele que apresentou o menor valor de AIC e BIC.

$$AIC(k, l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2(k + l)}{N} \quad [12]$$

$$BIC(k, l) = \ln \hat{\sigma}_{k,l}^2 + (k + l) \frac{\ln N}{N} \quad [13]$$

Onde $\hat{\sigma}_{k,l}^2$ é a variância estimada de erros; k e l são os valores dos parâmetros do modelo e N é o tamanho da amostra.

A previsão do modelo ajustado foi realizada no software R, utilizando os pacotes *forecast* e *timeSeries* e a sua validação foi efetivada através da comparação entre os valores observados e valores preditos tendo em conta o MAE (Erro Médio Absoluto) (equação 14) o r (coeficiente de correlação de Person) (equação 15), C_{NS} (coeficiente de Nash e Sutcliffe) (equação 16), Pbias (percentual de viés) (equação 17) e o R² (coeficiente de determinação) (equação 18). Todas as análises foram realizadas considerando um nível de significância de 5%.

$$MAE = \frac{1}{n} \sum (P_o - P_t) \quad [14]$$

$$r = \frac{\text{cov}(P_o, P_t)}{\sqrt{\text{var}(P_o)\text{var}(P_t)}} = \frac{\sum(P_o - \bar{P}_o)(P_t - \bar{P}_t)}{\sqrt{\sum(P_o - \bar{P}_o)^2(P_t - \bar{P}_t)^2}} \quad [15]$$

$$C_{NS} = 1 - \frac{\sum(P_o - P_t)^2}{\sum(P_o - \bar{P}_o)^2} \quad [16]$$

$$P_{bias} = \left[\frac{\sum(P_o - P_t)}{\sum P_o} \right] \times 100\% \quad [17]$$

$$R^2 = \left(\frac{\sum(P_o - \bar{P}_o)(P_t - \bar{P}_t)}{\sqrt{\sum(P_o - \bar{P}_o)^2(P_t - \bar{P}_t)^2}} \right)^2 \quad [18]$$

onde: P_o e P_t são dados observados e estimados respectivamente

O erro médio absoluto (MAE) varia de 0 a $+\infty$, quanto mais próximo estiver do zero, melhor é o modelo.

O coeficiente de correlação de Pearson varia de -1 a 1 sendo que quanto mais próximo de 1, maior é a tendência de existir uma dependência linear entre as variáveis. A Tabela 1 mostra a classificação do modelo pelo coeficiente de correlação de Pearson.

Tabela 1- Classificação do modelo pelo coeficiente de correlação de Pearson

r	classificação
> 0,9	Correlação muito forte
0,7 a 0,9	Correlação forte
0,5 a 0,7	Correlação moderada
0,3 a 0,5	Correlação fraca
0 a 0,3	Correlação despresível

Fonte: (Oliveira, 2019).

O coeficiente de Nash e Sutcliffe é um dos mais importantes critérios para avaliar o poder preditivo de modelos hidrológicos, ele varia de $-\infty$ a 1, quanto mais próximo de 1 mais preciso é o modelo de estimativa dos dados avaliados (Silva et al., 2007). A adequação dos modelos em função do coeficiente de Nash Sutcliffe é dada pela Tabela 2.

Tabela 2- Adequação do modelo pelo coeficiente de Nash Sutcliffe

C _{NS}	Classificação	autor
0,36 a 0,75	Aceitável	
> 0,75	Adequado	Gottschalk et al (2009)
1	Perfeito	
0,5 a 0,54	Satisfatório	
0,54 a 0,65	Bom	Moriasi et al (2007)
> 0,65	Muito bom	
< 0,2	Insuficiente	
0,2 a 0,4	Satisfatório	
0,4 a 0,6	Bom	Molnar (2011)
0,6 a 0,8	Muito bom	
> 0,8	Excelente	

Fonte: (Oliveira, 2019)

O Pbias representa a média dos erros individualizados, e é geralmente utilizado para saber se há superestimativa ou subestimativa média dos valores estimados. O valor positivo e negativo de Pbias indica superestimação e subestimação respectivamente e Pbias igual a zero,



afirma que não há erro sistemático ou tendência no conjunto de dados estimados (Mahmood; Jia, 2016).

O coeficiente de determinação é uma medida descritiva da qualidade de ajuste do modelo ele varia de 0 a 1,0. Quanto mais próximo de 1 ele estiver mais perfeito será o ajuste do modelo aos dados observados (Oliveira, 2019).

3. RESULTADOS E DISCUSSÃO

3.1. Análise Descritiva da Precipitação

Durante o período analisado, a precipitação média mensal foi estimada em 86,93 mm, sendo que o período chuvoso se inicia no mês de outubro, com chuvas abaixo da média anual, atingindo o seu ponto máximo no mês de janeiro, e se encerra no mês de abril (Figura 3). Posteriormente, o período de seca inicia-se em maio e perdura até o mês de setembro.

Figura 3- Distribuição da Precipitação Média Mensal na Cidade de Chimoio entre 1989 e 2022



Fonte: Elaborado pelos autores (2024).

A análise estatística da precipitação mensal no período compreendido entre 1989 e 2022 apresentada na Tabela 3, indica que a precipitação varia de 0 a 574,8 mm, sendo que a máxima precipitação foi registrada no mês de janeiro e a mínima ocorreu no mês de agosto.

O coeficiente de assimetria mede a forma como os dados estão distribuídos em relação à média enquanto que o coeficiente de Curtose mede o grau de planicidade da frequência de distribuição dos dados (Mello; Silva; Beskow, 2021). O coeficiente de Curtose negativo e positivo indica que a distribuição é mais plana e mais afunilada que a distribuição normal respectivamente.

O coeficiente de Curtose variou de -0,71 a 17,91, com os valores negativos a serem observados nos meses de janeiro, fevereiro, novembro e dezembro, sendo o valor mínimo registrado em dezembro. Nos demais meses, observaram-se valores positivos, com o máximo verificado em setembro. O coeficiente de assimetria apresentou valores que variam de 0,11 a 3,76, sendo o valor mínimo observado em novembro e o máximo em setembro. A presença de assimetria positiva indica que eventos de precipitação mais intensa ocorrem com menor frequência, enquanto valores mensais de chuva inferiores à média são registrados com maior regularidade (Chitrakar; Sana; Almalki, 2023).

Tabela 3- Estatística descritiva da precipitação mensal em Chimoio no período de 1989-2022

Mês	min (mm)	max (mm)	média (mm)	Q ₁ (mm)	Q ₃ (mm)	Desvio Padrão (mm)	Kurtose	Assimetria
Janeiro	19,7	574,8	251,54	166,28	327,93	142,51	-0,17	0,46
Fevereiro	9,9	516,6	189,87	84,85	266,25	129,20	-0,30	0,77
Março	13,6	499,4	136,59	57,85	190,63	104,09	3,68	1,70
Abril	6,6	215,1	69,09	31,63	80,65	52,00	1,98	1,54
Maio	0,3	70,1	15,61	4,40	18,88	14,83	4,76	1,87
Junho	0	48,2	13,44	3,28	20,40	14,18	0,88	1,38
Julho	0	53,1	16,10	4,63	25,53	14,06	0,06	0,89
Agosto	0	48,9	12,23	3,15	14,98	10,72	3,20	1,48
Setembro	0	114,8	16,46	5,98	23,58	20,25	17,91	3,76
Outubro	0,4	120,5	38,56	10,75	61,53	33,91	0,09	0,96
Novembro	0	170,7	79,72	39,43	111,60	46,76	-0,64	0,11
Dezembro	38,5	472	215,94	97,68	279,20	125,72	-0,71	0,35

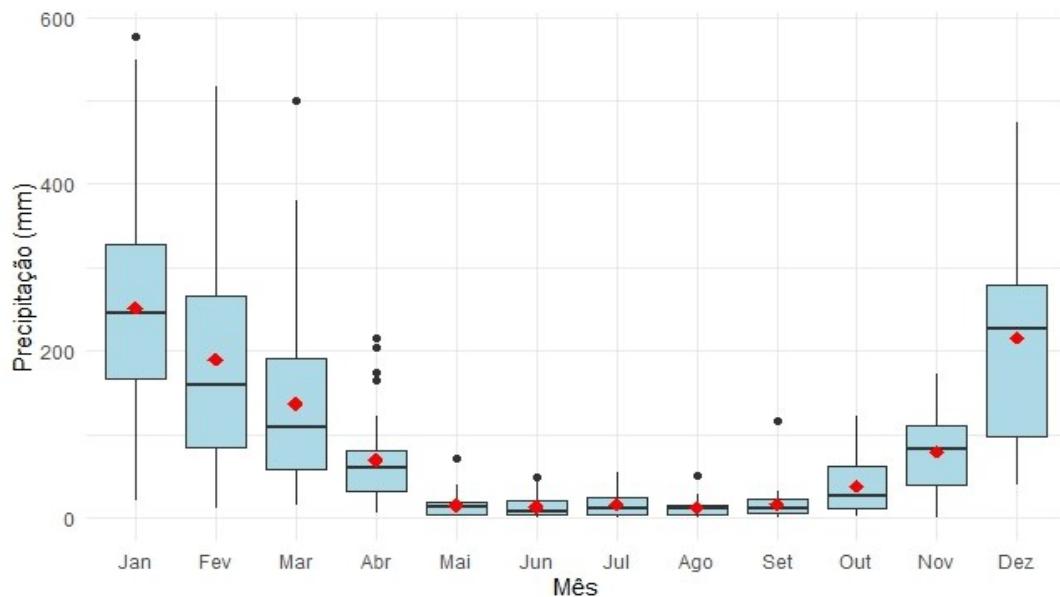
Fonte: Elaborado pelos autores (2024).

A Figura 4 mostra o gráfico boxplot das precipitações médias em Chimoio, no qual se observa que os meses chuvosos apresentam uma maior variabilidade na precipitação quando comparados aos meses secos. As maiores variabilidades podem ser observadas nos meses de

janeiro, fevereiro, dezembro e março, respectivamente. Segundo Rocha e Simmonds (1997) o mês janeiro é o pico de verão e as chuvas são predominantemente de natureza convectiva.

Os meses de novembro e dezembro apesar de apresentar um coeficiente de assimetria positivo, tiveram maior número de eventos de chuvas acima da precipitação média em comparação com os outros, muitos destes eventos estiveram associados ao fenômeno La Niña. Por outro lado, os meses de fevereiro e março tiveram maior número de eventos de chuvas abaixo da precipitação média, muitos destes eventos estiveram associados ao El Niño. Vários estudos confirmam uma relação entre a precipitação e o El Niño-Oscilação Sul (ENOS) na África Austral. Esse fenômeno provoca diminuição (El Niño) e aumento (La Niña) de precipitação no período de sua vigência, normalmente entre outubro e março do ano hidrológico (Nicholson; Kim; Jeeyoung, 1997; Tique, 2015; Macie; Freitas, 2016).

Figura 4- Gráfico de caixas da precipitação média observada em Chimoio no período de 1989-2022



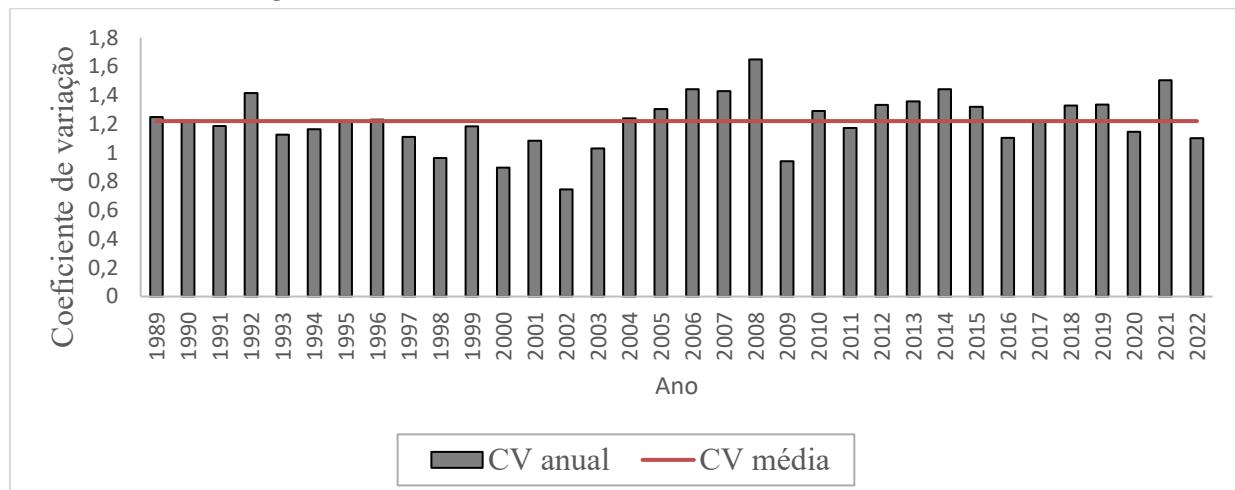
Fonte:Elaborado pelos autores (2024).

Em termos de variabilidade anual (Figura 5), observa-se que a maior variação ocorreu no ano de 2008 e a menor em 2002, a grande variabilidade na precipitação em 2008 esteve associada a um episódio intenso de La Niña, conforme categorização apresentada na Tabela de intensidades do ENOS disponível em link <https://ggweather.com/enso/oni.htm>. Também, nota-se que em anos sem ocorrência ou com La Niña fraco como é caso dos anos 2004, 2005, 2006, 2013, 2018 e 2019, bem como anos com grande intensidade do El Niño como é o caso do ano 2015 tiveram uma variabilidade de precipitação acima da média, explica-se pelo facto

das mudanças de pressão sobre o oceano índico também exercem influência na precipitação pluviométrica da região, mesmo em anos de ocorrência de ENOS (Rocha; Simmonds, 1997; Tique, 2015; Macie; Freitas, 2016).

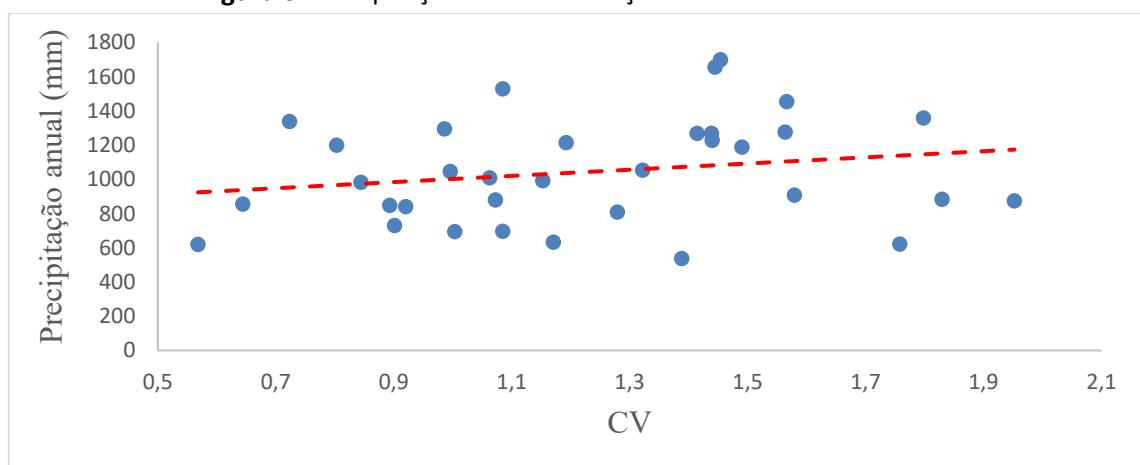
Além disso, pode-se observar na Figura 6 uma tendência de aumento do coeficiente de variação com o aumento da precipitação anual, sugerindo que anos mais chuvosos tendem a ter maior variabilidade temporal da precipitação em comparação com anos menos chuvosos, ou seja em anos em que se regista maior precipitação há uma tendência de ter chuvas concentradas num único mês, geralmente nos meses de janeiro e dezembro.

Figura 5- Variabilidade mensal da precipitação num dado ano



Fonte: Elaborado pelos autores (2024).

Figura 6- Precipitação anual em função da variabilidade mensal



Fonte: Elaborado pelos autores (2024).

3.2. Tendência da precipitação

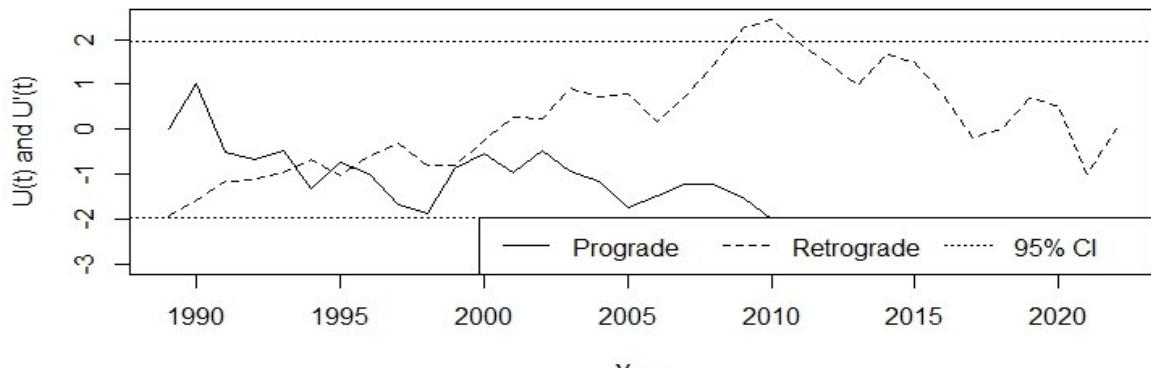
A análise de tendência da série histórica de precipitação foi realizada por meio do teste não paramétrico de Mann-Kendall, considerando um nível de significância de 5%. Os resultados obtidos estão sumarizados na Tabela 2. O resultado do teste de tendência mensal no período de 1989 a 2022, indicou uma tendência negativa significativa para o mês de agosto, mostrando uma diminuição da precipitação no mês ao longo dos anos, consoante a forma gráfica do teste de Mann-kendall apresentada na Figura 6, observa-se que esta tendência tornou-se significativa a partir do ano de 1994, ano caracterizado com precipitações anuais muito abaixo da média e com uma variabilidade considerável (Figura 5), sendo que o mês de agosto teve uma queda brusca de precipitação. Para os demais meses incluindo a precipitação anual, mostraram tendências não significativas.

Tabela 3- teste de tendência de Mann-Kendall.

Dados analisados	Zscore	Estado da Tendência	Tendência
Precipitação (1989-2022)	Janeiro	-0,1482	Não significativo
	Fevereiro	-0,2075	Não significativo
	Março	1,097	Não significativo
	Abril	1,186	Não significativo
	Maio	-0,2818	Não significativo
	Junho	-0,0741	Não significativo
	Julho	-0,6968	Não significativo
	Agosto	-1,9875	Significativo
	Setembro	-1,0972	Não significativo
	Outubro	-0,8304	Não significativo
	Novembro	-0,3854	Não significativo
	Dezembro	1,097	Não significativo
Anual		1,1267	Não significativo
			p = 0,2599; S = 77,0

Fonte: Elaborado pelos autores (2024).

Figura 7- Estatística $U(t)$ e $U^*(t)$ do teste de Mann-Kendall.

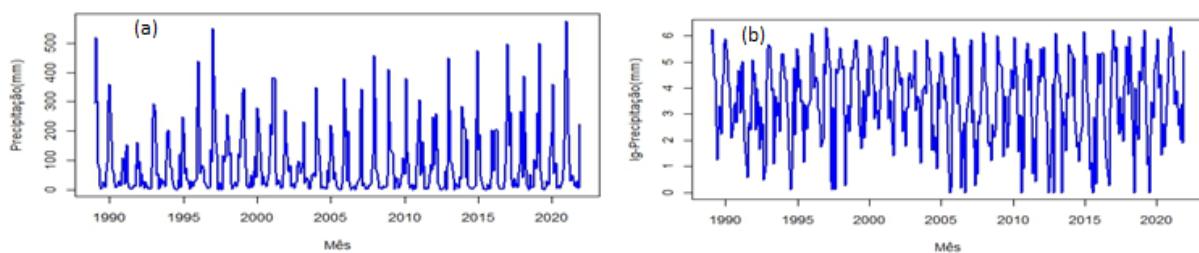


Fonte: Elaborado pelos autores (2024).

3.3. Modelagem da Série

A Figura 8 apresenta a série de precipitação mensal no período compreendido entre os anos 1989 e 2022. Observa-se que os picos com maiores amplitude representam os períodos de chuva e os de menor amplitude períodos de seca, com um ciclo de 12 meses caracterizando um padrão intra-anual de variabilidade. O teste de normalidade de Shapiro-Wilk (Ferreira, 2018), ditou a rejeição da hipótese nula ($p\text{-valor}<0,05$), o que confirma a não normalidade de dados. Com a realização do teste de Box-Cox (Sakia, 1992) resultou no valor de $\lambda=0,033$ sugerindo a utilização de uma transformação logarítmica nos dados, o que pode ser visto na Figura 9. O resultado obtido pelo teste de Dickey-Fuller Aumentado (ADF) indicou na rejeição da hipótese nula da raiz unitária ($p\text{-valor} < 0,05$), o que confirma a estacionalidade da série temporal.

Figura 8: Comportamento da série de precipitação mensal na cidade de Chimoio no período entre 1989-2022, (a) antes da transformação (b) após a transformação logarítmica.

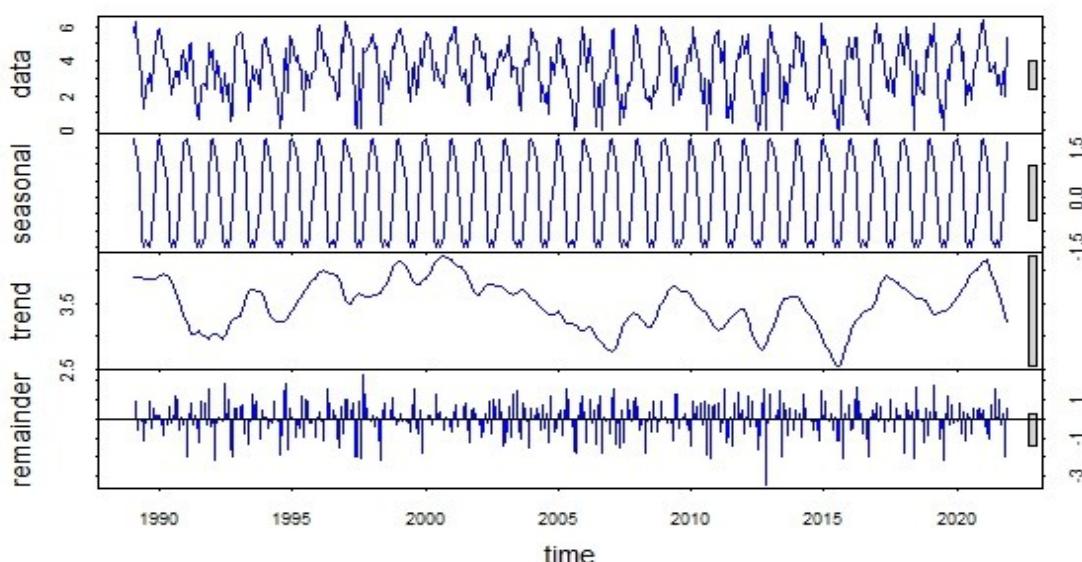


Fonte: Elaborado pelos autores (2024).

Pelo teste de Mann-Kendall com um nível de significância de 5%, verificou-se ausência da tendência nos dados, tendo em vista que o $p\text{-valor}$ foi de 0,467. Já para a componente de

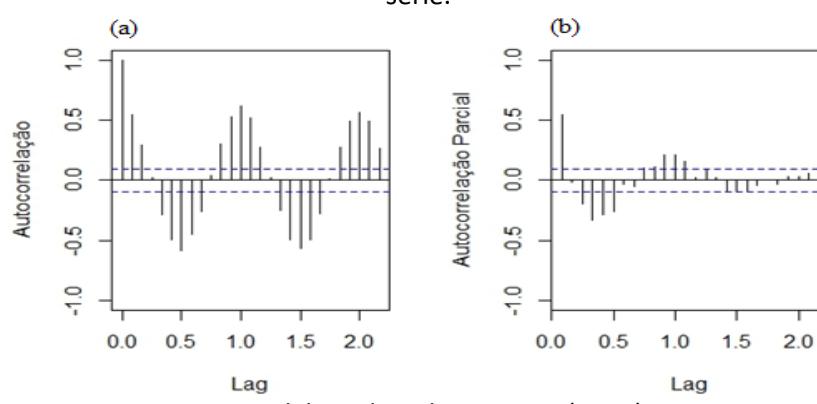
sazonalidade, o gráfico da decomposição da série apontou a presença de padrões que se repetem em específicas épocas do ano, bem como um comportamento senoidal na função de autocorrelação da série temporal, sugerindo a presença de uma componente sazonal. Esses resultados podem ser vistos nas Figuras 10 e 11, respectivamente.

Figura 10. Decomposição da série temporal em componentes de sazonalidade, de tendência e de aleatoriedade.



Fonte: Elaborado pelos autores (2024).

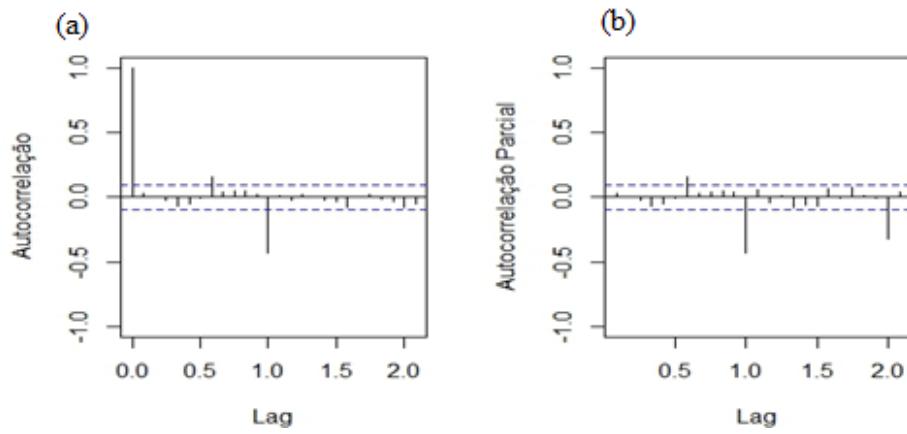
Figura 11. Função de autocorrelação amostral (a) e função de autocorrelação parcial amostral (b) da série.



Fonte: Elaborado pelos autores (2024).

Tendo em vista a presença da componente sazonal, realizou-se uma diferença sazonal na série temporal de período de 12 meses. Após a realização da primeira diferença sazonal, observa-se, por meio da Figura 12, o comportamento do correlograma.

Figura 12. Função de autocorrelação amostral (a) e função de autocorrelação parcial amostral (b) da série após a remoção da sazonalidade.



Fonte: Elaborado pelos autores (2024).

Obtida a série, procedeu-se com a estimativa de modelos da classe SARIMA (p, d, q) (P, D, Q) s , visando encontrar os modelos que melhor se ajustam e descrevem a série de precipitação na cidade de Chimoio. Foram escolhidos três modelos, dispostos na Tabela 5, por apresentarem resíduos não correlacionados ou ruído branco.

Tabela 5. Modelos Sarima selecionados.

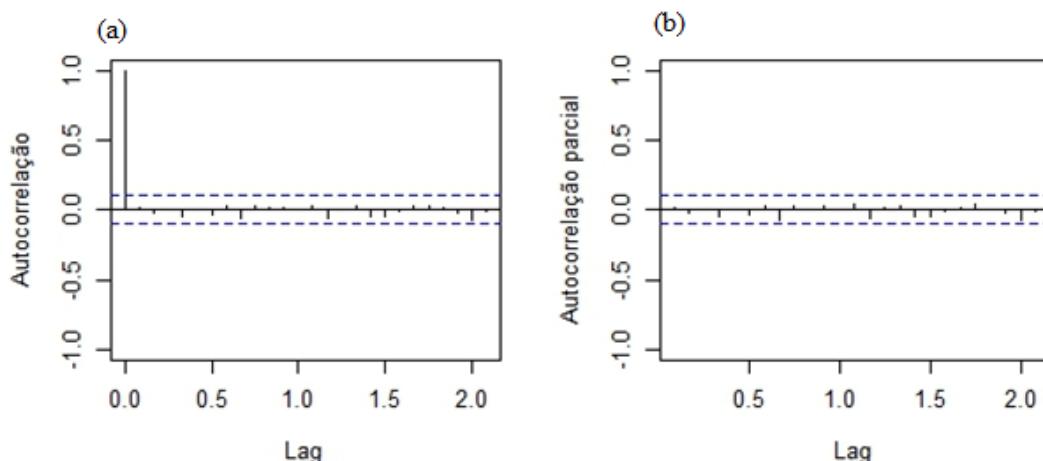
Modelo	AIC	BIC
SARIMA $(7,0,1)(0,1,1)_{12}$	1112,51	1132,27
SARIMA $(2,0,2)(0,1,1)_{12}$	1120,40	1144,10
SARIMA $(1,0,1)(0,1,1)_{12}$	1120,86	1136,66

Fonte: Elaborado pelos autores (2024).

3.4 Critério de Escolha do modelo

O modelo mais adequado a série foi o SARIMA $(7,0,1)(0,1,1)_{12}$, com valores para AIC de 1112,51 e BIC de 1132,27. Conforme os valores de FAC e FACP mostrados na Figura 13 foi possível identificar que os resíduos se apresentaram não correlacionados, esta conclusão também pode ser sustentada pelo teste de Liung-Box-Pierce que indicou $pval = 0,96139$, mostrando que a série de resíduos apresenta comportamento de ruído branco.

Figura 13. Função de autocorrelação (a) e função de autocorrelação parcial (b) do resíduo.



Fonte: Elaborado pelos autores (2024).

3.5 Previsão e Validação do modelo

Através das estatísticas de avaliação do ajuste de modelos (Tabela 2), nomeadamente o MAE, r, C_{NS}, R² e Pbias foi possível observar que a série prevista apresentou um bom ajuste em relação aos dados observados sendo que o MAE foi de 51,6mm, r foi de 0,83 indicando uma correlação forte entre os valores observados e os estimados, C_{NS} foi de 0,58 enquadrando-se na classificação de desempenho satisfatório, conforme os parâmetros definidos por Moriasi et al. (2007) e Molnar (2011) e aceitável segundo Gottschalk (2009), o Pbias indicou uma subestimação do modelo em 32% e o R² foi de 0,7, modelos com valores semelhantes de MAE e R² foram validados por Valipour (2015), Dimri, Ahmad e Sharif (2020), Lima et al. (2020) e Santos, Delfino e Santos (2021) em seus estudos.

Apesar de ter bons indicadores estatísticos, o modelo não se ajustou adequadamente para os meses em que não se registrou a precipitação, sendo que para esses períodos o modelo está a superestimar o valor da precipitação, segundo Lima et al. (2020) isto deve-se para todos os casos observados a uma variação brusca da precipitação em relação ao dia anterior o que dificulta a previsão do modelo.

Os intervalos de confiança a 95% gerados através do modelo ajustado (Tabela 2) e (Figura 14) contiveram os doze valores reais de precipitação pluviométrica média mensal para o ano de 2022.

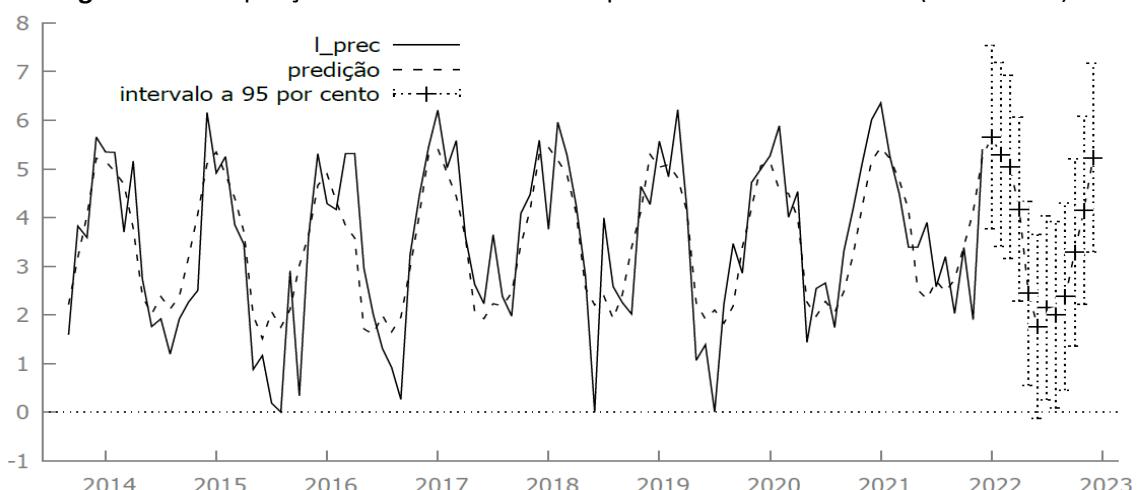
Tabela 6. Estatística comparativa entre os valores observados e valores estimados pelo modelo.

Mês	Estimado	Observado	Limite inferior	Limite superior
Janeiro	286,83	296,6	42,22	1948,67
Fevereiro	198,42	517,6	29,13	1351,4
Março	153,3	87,9	22,48	1045,24
Abril	63,97	75,7	9,38	436,42
Maio	11,64	12,8	1,71	79,46
Junho	5,93	3,5	0,87	40,5
Julho	8,51	10,8	1,25	58,07
Agosto	7,46	27,6	1,07	52,03
Setembro	10,65	9,3	1,51	75,15
Outubro	26,6	62,2	3,75	188,86
Novembro	60,86	93	8,54	433,46
Dezembro	186,62	304,39	26,16	1331,55

MAE = 51,6 mm
 $r = 0,83$
 $R^2 = 0,70$
 $C_{NS} = 0,58$
 $Pbias = -32,0\%$

Fonte: Elaborado pelos autores (2024).

Figura 14. Precipitação observada e estimada pelo SARIMA em Chimoio (1989–2022).



Fonte: Elaborado pelos autores (2024).

4. CONCLUSÃO

Os resultados deste trabalho permitem concluir que a variabilidade da precipitação na região estudada foi maior nos meses chuvosos se comparado com os meses secos, com destaque para os meses de dezembro, janeiro, fevereiro e março. Por sua vez, o mês de agosto revelou-se como o período com menor variabilidade.

Com base na análise da variabilidade anual, conclui-se que os eventos climáticos associados ao fenômeno ENOS (El Niño Oscilação Sul) e as mudanças de pressão sobre o oceano Índico tem influência considerável na variabilidade das chuvas na região.

O estudo avaliou ainda a presença de tendências climáticas mensais nas séries históricas de precipitação. A aplicação do teste de Mann-Kendall apontou uma tendência negativa estatisticamente significativa no mês de agosto, sugerindo uma possível redução da precipitação ao longo dos anos, com essa tendência se tornando estatisticamente significativa a partir de 1994.

O modelo SARIMA (7,0,1)(0,1,1)₁₂ ajustado teve um bom ajuste, uma vez que todos os indicadores estiveram dentro dos padrões estabelecidos. As projeções realizadas para o ano de 2022 permaneceram dentro dos limites do intervalo de confiança de 95% estabelecido pelo modelo, mesmo considerando as incertezas e eventuais variações decorrentes de fatores climáticos.

Diante desse desempenho, o modelo demonstrou potencial para aplicação prática, podendo ser utilizado pelo Instituto Nacional de Meteorologia (INAM) para o preenchimento de falhas em séries de dados de precipitação, bem como pela administração municipal de Chimoio no planejamento de projetos voltados à gestão de recursos hídricos, especialmente no que diz respeito ao sistema de drenagem urbana.

REFERÊNCIAS

- ABDUL-AZIZ, A.; ANOKYE, M.; KWAME, A.; MUNYAKAZI, L.; NSOWAH-NUAMAH, N. Modeling and Forecasting Rainfall Pattern in Ghana as a Seasonal Arima Process: The Case of Ashanti Region. *International Journal of Humanities and Social Science*, p. 223-233, 2013.
- AHMAD, I.; TANG, D.; WANG, T. F.; WANG, M.; WANG, B. Precipitation trends over time using Mann-Kendall and Spearman's rho tests in Swat River basin, Pakistan. *Advances in Meteorology*, v. 2016, 2015.

ALCÂNTARA, L. R. P.; COSTA, I. R. A.; BARROS, V. H. O.; SANTOS NETO, S. M.; COUTINHO, A. P.; ANTONINO, A. C. D. Análise de tendência para dados pluviométricos no município de Toritama-PE. **Journal of Environmental Analysis and Progress**, v.4, n.2, p.130-139, 2019.

BACK, A. J. Aplicação de análise estatística para identificação de tendências climáticas. **Pesquisa Agropecuária Brasileira**, v. 36, n. 5, p. 717-726, 2001.

BANCO MUNDIAL. *Banco Mundial apoia maior capacidade de resiliência aos riscos relacionados com o clima em Moçambique*. Washington, DC: Banco Mundial, 23 dez. 2014. Disponível em: <https://www.worldbank.org/pt/news/press-release/2014/12/23/world-bank-supports-greater-resilience-to-climate-related-hazards-in-mozambique>. Acesso em: 30 abr. 2025.

BARBOSA, W. G.; CARVALHO, J. M.; SILVA, D.H.L.; SILVA JÚNIOR, A.N.; ARAÚJO, L. S.; SILVA, A.S.A.; FERREIRA, T.A.E.; CRISTINO, C.T.; STOSIC, T. Sazonalidade do regime de chuvas nas mesorregiões do estado de Pernambuco, Brasil. **Pesquisa, Sociedade e Desenvolvimento**, v. 12, 2023.

BOX, G. E.; JENKINS, J. M. *Time Series Analysis: Forecasting and Control*. 2. ed. San Francisco: Holden-Day, 1976.

BRITO, A. P.; SILVA, N. C.; TOMASELLA, J.; FERREIRA, S. J.; MONTEIRO, M. T. Análise do Índice de Anomalia de Chuva e Tendência de Precipitação para Estações Pluviométricas na Amazônia Central. **Revista Brasileira de Meteorologia**, p.19-30, 2022.

CHITRAKAR, P.; SANA, A.; ALMALKI, S. H. Regional distribution of intensity-duration-frequency (IDF) relationships in Sultanate of Oman. **Journal of King Saud University – Science**, p. 1-14, 2023.

CLIMATE-DATA. Climate-Data.Org. Moçambique, 2024. Disponível em: <https://pt.climate-data.org/africa/mocambique-88/>. Acesso em: mar. 2024.

DFID (Department for International Development). *Reducing the risk of disasters – helping to achieve sustainable poverty reduction in a vulnerable world: a DFID policy paper*. London, 2006.

DIMRI, T.; AHMAD, S.; SHARIF, M. Time series analysis of climate variables using seasonal ARIMA approach. **J. Earth Syst. Sci**, p.129-149, 2020.

FERREIRA, D. **Estatística básica**. 2. ed. Lavras: UFLA, 2018.

GOTTSCHALK, L. Macro-scale hydrological modelling - A scandinaviam experience. **Hydrological Sciences Journal**, p. 46:963-982, 2009.

GUEDES, H. A.; PRIEBE, P.; MANKE, E. B. Tendências em séries temporais de precipitação no norte do estado do Rio Grande do Sul, Brasil. **Revista Brasileira de Meteorologia**, p. 283-291, 2019.

ELY, D. F.; DUBREUIL, V. Análise das tendências espaço-temporais das precipitações anuais para o estado do Paraná–Brasil. **Revista Brasileira de Climatologia**, v. 21, p.553-569, 2017.

HUNTRA, P.; KEENER, T. C. Evaluating the impact of meteorological factors on water demand in the las vegas valley using time-series analysis: 1990–2014. **International Journal of Geo-Information**, p.1-19, 2017.

INGRAM, M. R. Constraints on future changes. **NATURE**, p.224-232, 2002.

ISHAK, E.H.; RAHMAN, A.; WESTRA, S.; SHARMA, A.; KUCZERA, G. Evaluating the non-stationarity of Australian annual maximum flood. **Journal of Hydrology**, v. 494, p. 134-145, 2013.

JHAJHARIA, D.; CHATTOPADHYAY, S.; CHOUDHARY, R. R.; DEV, V.; SINGHE, V. P. Influence of climate on incidences of malaria in the Thar Desert, northwest India. **International journal of climatology**, p.312–325, 2013.

KIM, B. S.; HOSSEIN, S. Z.; CHOI, G. Evaluation of Temporal-spatial Precipitation Variability and Prediction Using Seasonal ARIMA Model in Mongolia. **KSCE Journal of Civil Engineering**, p.917-925, 2011.

LACERDA, M. S.; MARTINS, H. S. R.; TEMOTEO, A. S.; EMILIANO, P. C. Precipitação pluviométrica em Viçosa-MG: um estudo via séries temporais. **Revista Agrogeoambiental**, v.14, 2022.

LIMA, L. P.; JÚNIOR, A. A.; CARVALHO, A. C.; MUSIS, C. R. Utilização de estatística descritiva e de modelo sarima no estudo de precipitação na região sudeste de MATO GROSSO. **Revista de ciências ambientais**, 2020.

LIMA, P.R. C.; ANDRADE, A. R.; OLIVEIRA, J.V.P.; LUCENA, D. B. Identificação de tendências nas séries temporais de precipitação na microrregião do Alto Sertão Paraibano. **Revista AIDIS de ingeniería y ciencias ambientales: Investigación, desarrollo y práctica**, v.14, n.1, p.1-18, 2021.

MACIE, O. A.; FREITAS, E. D. Características da estação chuvosa em Moçambique e probabilidade de ocorrência de períodos secos. **Revista do Centro de Ciências Naturais e Exatas – UFSM**, p.232 – 239, 2016.

MAHMOOD, R.; JIA, S. Assessment of Impacts of Climate Change on the Water Resources of the Transboundary Jhelum River Basin of Pakistan and India. **Water**, p. 8-246, 2016.

MARENGO, J.A; NOBRE, C.A.; TOMASELLA, J.; OYAMA, M.D.; OLIVEIRA, G.V.S.; OLIVEIRA, R.; CAMARGO, H.; ALVES, L.M.; BROWN, F. The drought of Amazonia in 2005. **Journal of Climate**, v. 21, n. 3, p. 495-516, 2008.

MELLO, C. R.; SILVA, A. M.; BESKOW, S. **Hidrologia de superfície: Princípios e aplicações**. Lavras: UFLA, 2021.

MENEZES, F. P.; FERNANDES, L. L. Análise de tendência e variabilidade da precipitação no Estado do Pará. **Enciclopédia Biosfera**, Centro Científico Conhecer - Goiânia, v.13, n.24, p.1580-1591, 2016.

MOLNAR, P. Calibration: watershed modelling. **SS. Switzerland: Institute of Environmental Engineering, Chair of Hydrology and Water Resources Management, ETH Zurich**. 2011.

MOREIRA, J.G.V.; NAGHETTINI, M. Detecção de tendências monotônicas temporais e relação com erros dos tipos I e II: estudo de caso em séries de precipitações diárias máximas anuais do estado do Acre. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 394-402, 2016.

MORIASI, D. N., ARNOLD, J. G., VAN LIEW, M. W., BINGNER, R. L., HARMEL, R. D., & VEITH, T. L. Model evaluation guidelines for systematic quantification of accuracy IN watershed simulations. **American Society of Agricultural and Biological Engineers**, ISSN 0001-2351, Vol. 50(3). p. 885–900, 2007.

NICHOLSON, S. E., KIM; JEEYOUNG. The relationship of the el niño–southern oscillation to african rainfall. **International journal of climatology**, v. 17. p. 117-135, 1997.

OLIVEIRA, L. F. **Chuvas extremas no Brasil: modelos e aplicações**. Lavras: UFLA, 2019.

ROCHA, A.; SIMMONDS, I. Interannual variability of south-eastern african summer rainfall. part 1: relationships with air–sea interaction processes. **International Journal of Climatology**, p.235–265, 1997.

SAKIA, R. M. The Box-Cox transformation technique: a review. **The Statistician**. doi:10.2307/2348250. 1992.

SANTOS, F. A.; AQUINO, C. M. Análise da precipitação pluviométrica no município de Castelo do Piauí, Nordeste do Brasil. **Geo Usp**, p. 619-633, 2017.

SANTOS, P. H.; DELFINO, O. A.; SANTOS, R. V. Ajuste de um modelo de séries temporais para prever a precipitação pluviométrica. **Research, Society and Development**, v. 10, n. 6. p. 1-11, 2021.

SENEVIRATNE S.I.; NICHOLLS, N.; EASTERLING, D. Changes in climate extremes and their impacts on the natural physical environment. In: FIELD, C.B.; BARROS, V.; STOCKER, T.F.; QIN, D.; DOKKER, D.J.; EBI, K.L. et al. (eds). *Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation*. Cambridge: **Cambridge University Press**. p. 109-230, 2012.

SILVA JUNIOR, M. A. B.; FONSECA NETO, G. C.; CABRAL, J. J. S. P. Análise estatística para detecção de tendências em séries temporais de temperatura e precipitação no Recife-PE. **Revista de Geografia**, v.37, n. 1, p.222-240, 2020.

SILVA, P.; MELLO, C.; SILVA, A.; COELHO, G. Modelagem da hidrógrafa de cheia em uma bacia hidrográfica da região Alto Rio Grande. **Revista Brasileira de Engenharia Agrícola e Ambiental**, p.258-265, 2007.

TIQUE, A. T. **Análise da Climatologia Dinâmica da Variabilidade da Precipitação na Região Sudeste da África.** Dissertação (Mestrado) – São Paulo: Universidade de São Paulo, 2015.

VALIPOUR, M. Long-term runoff study using SARIMA and ARIMA models in the United States. **Meteorological applications.** 2015. p.592-598.

XU, D.; LIU, D.; YAN, Z.; REN, S.; XU, Q. Spatiotemporal Variation Characteristics of Precipitation in the Huaihe River Basin, China, as a Result of Climate Change. **Water**, p.1-15, 2023.

ZITA, L. E. **Eventos climáticos extremos nas bacias hidrográficas da África Subsaariana.** Dissertação (Mestrado) – Viçosa: Universidade Federal de Viçosa, 2023.