

ANÁLISE DE SÉRIES TEMPORAIS DE PRECIPITAÇÃO E TEMPERATURA NO MUNICÍPIO DE AREIA-PB UTILIZANDO MODELOS ESTATÍSTICOS ARIMA E ETS

Péricles de Farias Borges

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
pericles@cca.ufpb.br

Walter Esfrain Pereira

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
walter@cca.ufpb.br

José Jurandez Buriti de Melo Júnior

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
jurandez_j@hotmail.com

Adailson Tulio dos Santos Silva

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
adailsontulio6@gmail.com

Lázaro de Souto Araújo

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
lazaro.souto@hotmail.com

Thais Estefany Sinésio da Silva

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
thaisestefy@gmail.com

Patricia da Assunção Macedo

Universidade Federal da Paraíba, Centro de Ciências Agrárias, Areia, PB, Brasil
pmacedopaty007@gmail.com

RESUMO

Esta pesquisa analisou as séries temporais de precipitação e temperatura média mensal em Areia-PB, abrangendo de 1996 a 2023, empregando ARIMA (Média Móvel Integrada Autoregressiva) e ETS (Modelos de Espaço de Estado de Suavização Exponencial). A metodologia incluiu análises de séries temporais, com foco em determinar as características de erro, tendência e sazonalidade nos dados. Foi identificada uma tendência perceptível caracterizada por um declínio na precipitação, juntamente com uma elevação na temperatura após 2010. O modelo ARIMA exibiu maior eficácia, prevendo a persistência dessas tendências em 2023. A análise de decomposição da série revelou fortes flutuações sazonais e tendências duradouras. Os resultados demonstram um RMSE (Raiz do Erro Quadrático Médio) significativamente menor, para o modelo ARIMA, em comparação com o modelo ETS. Esta investigação ressalta a necessidade crítica de vigilância climática contínua e oferece informações significativas, para o gerenciamento de recursos hídricos e estratégias agrícolas na área, enfatizando o imperativo de metodologias adaptativas à luz das alterações climáticas detectadas.

Palavras-chave: Climatologia. Modelagem estatística. Sazonalidade.

TIME SERIES ANALYSIS OF PRECIPITATION AND TEMPERATURE IN THE MUNICIPALITY OF AREIA-PB USING ARIMA AND ETS STATISTICAL MODELS

ABSTRACT

This research analyzed the time series of monthly average precipitation and temperature in Areia-PB, covering the period from 1996 to 2023, employing ARIMA (Autoregressive Integrated Moving Average) and ETS (Exponential Smoothing State Space Models). The methodology included time series analysis focusing on identifying error, trend, and seasonality characteristics of the data. A noticeable trend was identified, characterized by a decline in precipitation along with a rise in temperature after 2010. The ARIMA model demonstrated greater efficacy, forecasting the persistence of these trends in 2023. The time series

decomposition analysis revealed strong seasonal fluctuations and enduring trends. The results showed a significantly lower RMSE (Root Mean Square Error) for the ARIMA model compared to the ETS model. This investigation highlights the critical need for continuous climate monitoring and provides significant insights for water resource management and agricultural strategies in the region, emphasizing the imperative for adaptive methodologies in light of the detected climate changes.

Keywords: Climatology. Statistical modeling. Seasonality.

INTRODUÇÃO

A mudança climática é predominantemente moldada por variações na dinâmica de temperatura e precipitação. A pesquisa focada, na avaliação das mudanças climáticas, depende significativamente da análise de dados de séries temporais referentes à temperatura e precipitação (BABAZADEH; SHAMSNI, 2014; BALIBEY; SERPIL, 2015). Esses dois fatores são essenciais para o planejamento estratégico, no gerenciamento de calamidades naturais, como inundações e secas. Nesse sentido, a análise de séries temporais surge como um método vital, facilitando a avaliação de tendências e padrões sazonais observáveis em dados climatológicos. Conforme articulado por Morettin e Tolo (2006), uma série temporal compreende uma coleção de observações organizadas cronologicamente que exibem dependência serial, permitindo o discernimento de padrões não aleatórios e a previsão de tendências futuras.

A análise de séries temporais é fundamental para compreender a dinâmica das mudanças climáticas (BALIBEY; SERPIL, 2015). Essa estrutura metodológica estabelece uma base robusta para a formulação de estratégias destinadas a aliviar os impactos negativos de fenômenos climáticos extremos, incluindo estresse térmico, inundações e condições de seca.

No domínio da modelagem agrofísica, a antecipação de variáveis meteorológicas é imperativa, contando com a extrapolação de registros históricos de séries temporais (KRZYSZCZAK et al., 2017). Entre a infinidade de metodologias de previsão, os modelos de Média Móvel Autorregressiva Integrada (ARIMA) atraíram recentemente um interesse considerável.

O fenômeno da mudança climática é predominantemente influenciado por flutuações nos padrões de temperatura e precipitação. No campo da modelagem agrofísica, a previsão de variáveis meteorológicas é de suma importância (KRZYSZCZAK et al., 2017). Os modelos de média móvel autorregressiva integrada (ARIMA) são particularmente valorizados como ferramentas robustas, para examinar a variabilidade climática, particularmente em relação aos parâmetros de temperatura e precipitação (MACHEKPOSHTI et al., 2018).

Esses modelos ARIMA são particularmente estimados como instrumentos proficientes, para analisar flutuações climáticas, principalmente em relação às métricas de temperatura e precipitação (MACHEKPOSHTI et al., 2018). Sua proficiência em capturar padrões intrincados, em conjuntos de dados temporais, torna-os indispensáveis para avaliações climáticas abrangentes e esforços de previsão precisos.

As ramificações das mudanças climáticas na agricultura representam uma preocupação crescente. O clima tem um impacto direto, em inúmeras atividades econômicas, influenciando o sucesso ou o fracasso de várias iniciativas, particularmente aquelas ligadas à produção agrícola (ALBUQUERQUE, 2015). De acordo com Assad et al. (2020), é provável que as mudanças climáticas aumentem a variabilidade da produtividade agrícola, que pode enfrentar reduções substanciais sem estratégias apropriadas de adaptação e mitigação. Essa variabilidade é especialmente pertinente, no estado da Paraíba, no qual a acentuada variabilidade espaço-temporal da precipitação pode levar a ocorrências extremas, como secas prolongadas ou chuvas significativas (DANTAS, 2016). Assim, a necessidade de dados climatológicos precisos relacionados a essas ocorrências é fundamental.

O aquecimento global constitui um dos principais desafios do século 21, com profundas repercussões, em vários domínios, incluindo recursos hídricos, agricultura, energia e infraestrutura (ASSAD et al., 2020). Investigações sobre mudanças climáticas e avaliações temporais revelaram tendências notáveis no aquecimento global, particularmente em contextos oceânicos. Cheng et al. (2019) enfatizam que o

excesso de energia térmica, absorvida pelos oceanos, resultou em temperaturas elevadas, atuando como uma métrica para quantificar a progressão do aquecimento global.

As repercussões das mudanças climáticas nas culturas agrícolas ressaltam a necessidade de uma modelagem preditiva eficaz (Rad et al., 2023). A temperatura do ar desempenha um papel crítico, pois afeta diretamente os processos fisiológicos da vida vegetal e animal e é vital para o planejamento agrícola e estudos sobre resiliência de culturas. Essa variabilidade é particularmente significativa, no estado da Paraíba, em que flutuações espaço-temporais pronunciadas na precipitação podem precipitar fenômenos extremos, incluindo secas prolongadas ou chuvas excessivas.

Em busca de uma compreensão científica dessa variabilidade, o emprego de modelos estatísticos em dados climáticos tem despertado interesse entre os estudiosos (ALBUQUERQUE, 2015). Esses modelos são criados, para encapsular os mecanismos subjacentes da série temporal, com base em dados históricos, facilitando assim o ajuste das tendências primárias e das características sazonais (MORETTIN; TOLOI, 2006).

Consequentemente, a seleção de culturas agrícolas adequadas, para uma determinada região, pode ser refinada, por meio de esclarecimentos derivados de dados climatológicos, que, por meio de coleta e análise sistemáticas, facilitam o perfil climático das áreas designadas. Diante disso, o presente estudo se justifica pela importância de elucidar a dinâmica temporal da precipitação, nas microrregiões do estado da Paraíba, contribuindo para a caracterização do regime de chuvas e auxiliando os produtores rurais na tomada de decisões informadas sobre o planejamento e execução de empreendimentos agrícolas.

Portanto objetivou-se nesta pesquisa examinar dados de séries temporais sobre precipitação e temperaturas médias mensais no município de Areia-PB, entre 1996 e 2020, empregando as abordagens de modelagem ARIMA e ETS. Esta investigação pretende descobrir padrões subjacentes, tendências e variações sazonais, avaliar a eficácia desses modelos na previsão mensal de precipitação e temperatura e fornecer informações críticas pertinentes ao gerenciamento de recursos hídricos e ao planejamento estratégico agrícola.

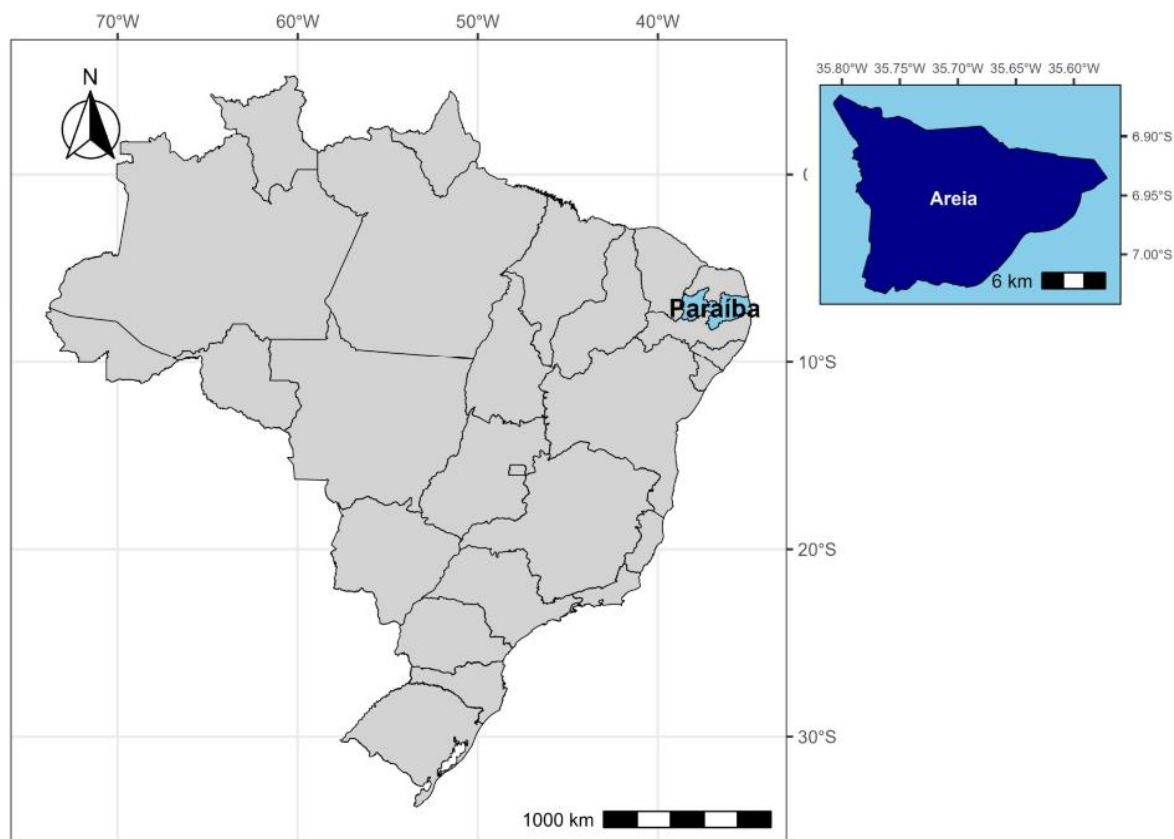
METODOLOGIA

O estudo foi realizado no município de Areia-PB, situado a uma latitude de 6° 58' 12" S e uma longitude de 35° 45' 15" W, posicionado a 127 km de João Pessoa, capital da Paraíba (Figura 1). A área de estudo está a uma altitude de 623 m acima do nível médio do mar, cobrindo aproximadamente 269.130 km². Areia-PB faz parte da microrregião do Brejo Paraibano e da mesorregião do Agreste Paraibano, abrigando uma população estimada de 22.493 indivíduos para o ano de 2021 (IBGE, 2022).

De acordo com Medeiros (2005), as condições climáticas de Areia-PB são classificadas como "As" (Köppen, 1936), indicando um clima tropical semiúmido caracterizado pela precipitação durante o período outono-inverno. Por outro lado, a classificação de Thornthwaite (1948) o categoriza como Ra 'a' B1, denotando um clima úmido com mínima deficiência de umidade, caracterizado como megatérmico com pequenas flutuações de temperatura (Figura 2).

Os dados climatológicos, incluindo precipitação e temperatura média, foram coletados mensalmente de janeiro de 1996 a dezembro de 2023, abrangendo um período de observação de 27 anos. Os dados foram provenientes da Estação Meteorológica do Centro de Ciências Agrárias da UFPB. Os dados coletados foram inicialmente organizados usando planilhas Excel para organização preliminar e, em seguida, analisados utilizando o software R Core Team (2024) para análises estatísticas mais avançadas e representações gráficas.

Figura 1 - Localização da Área de Estudo



Fonte: Os autores, (2024).

Uma análise temporal foi realizada construindo séries temporais para o período designado. Essas séries sofreram uma decomposição clássica, para separar componentes de tendência, variações sazonais e resíduos, permitindo o discernimento de padrões sazonais e tendências em longo prazo nos parâmetros analisados. Para avaliar a distribuição mensal e a variabilidade sazonal, gráficos de caixa sazonais foram desenvolvidos, aprimorando a compreensão da dispersão de dados, identificação de valores discrepantes e detecção de variações ao longo de meses e anos.

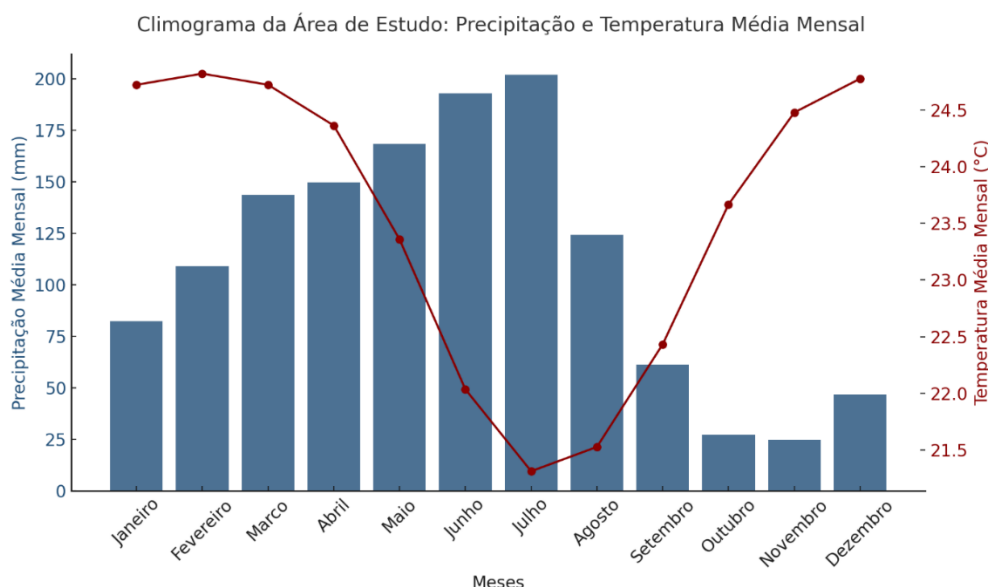
Funções de autocorrelação (ACF) foram aplicadas às séries temporais, essenciais para entender a estrutura de dependência temporal dos dados e auxiliar na identificação de modelos preditivos adequados.

A modelagem de séries temporais foi conduzida utilizando duas metodologias: ETS (erro, tendência, sazonalidade) e modelos sazonais ARIMA. Os modelos ETS, conforme descrito por Hyndman et al. (2008), permitem diferentes combinações de erro (aditivo ou multiplicativo), tendência (nenhuma, aditiva, aditiva amortecida, multiplicativa ou multiplicativa amortecida) e componentes de sazonalidade (nenhuma, aditiva ou multiplicativa). Essa flexibilidade permite que o modelo capture efetivamente vários padrões nos dados.

Os modelos ARIMA, formulados na década de 1970 por George Box e Gwilym Jenkins, também foram empregados. Esses modelos dependem fundamentalmente da calibração dos pontos de dados observados, visando minimizar a discrepância entre os valores gerados pelo modelo e aqueles observados empiricamente (Box e Jenkins, 1976; Sato, 2013). O modelo ARIMA (p,d,q) incorpora

componentes autorregressivos (AR) de ordem p , diferenciação de ordem d para alcançar estacionariedade e componentes de média móvel (MA) de ordem q .

Figura 2 - Climograma da Área de Estudo: Precipitação e Temperatura Média Mensal do município de Areia-PB, no período avaliado de 1996 a 2023



Fonte: Os autores, (2024).

O ARIMA também é frequentemente chamado de método de séries temporais de Box-Jenkins. O ARIMA é muito preciso para previsões em curto e longo prazo. O ARIMA pode ser interpretado como uma combinação de dois modelos: o modelo Autorregressivo (AR) integrado com o modelo Média Móvel (MA) Makridakis et al., 2020. O modelo ARIMA é geralmente escrito com a notação ARIMA (p,d,q), em p é a ordem do processo AR, d é a ordem de diferenciação e q é a ordem do processo MA.

De acordo com Box e Jenkins, o ARIMA (p,d,q) pode ser expresso na Equação (1):

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (1)$$

Em que:

$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ operador de defasagem (AR),

$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ operador de defasagem (MA),

B operador de defasagem,

$(1-B)^d$ operador de diferenciação,

d ordem de diferenciação.

A Equação (1) pode ser reescrita como:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t \quad (2)$$

O modelo ARIMA (p,d,q) é uma combinação dos modelos AR (p) e MA (q) com padrões de dados não estacionários, seguido de diferenciação de ordem dd . Vários modelos de séries temporais para dados estacionários são os seguintes:

Modelo Autorregressivo (AR)

O modelo autorregressivo é uma forma de regressão que conecta a variável dependente com valores anteriores, em um intervalo de tempo, de modo que um modelo autorregressivo expressa uma previsão como uma função de valores anteriores dos dados da série temporal. O modelo autorregressivo de ordem AR (p) ou modelo ARIMA (p,0,0) é expresso na Equação (3):

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (3)$$

A Equação (3) pode ser escrita usando o operador de defasagem (B) como:

$$\phi_p(B)Z_t = a_t \quad (4)$$

Em que $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é chamado de operador AR (p).

Modelo de Média Móvel (MA)

Outro modelo do ARIMA é o modelo de média móvel, denotado como MA (q) ou ARIMA (0,0,q), que é escrito na Equação (5):

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (5)$$

A Equação (5) pode ser escrita usando o operador de defasagem (B) como:

$$Z_t = \theta_q(B)a_t \quad (6)$$

Em que $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é chamado de operador MA (q).

Os modelos ETS (Modelos de Espaço de Estado de Suavização Exponencial) são amplamente utilizados, para a previsão de séries temporais, proporcionando uma abordagem baseada no espaço de estados que integra os componentes de erro, tendência e sazonalidade. A estrutura geral pode ser aditiva ou multiplicativa (Hyndman et al., 2008).

Equações do modelo ETS

Componente de Nível (Nível atual):

$$\ell_t = \alpha \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha)(\ell_{t-1} - b_{t-1}) \quad (\text{multiplicativo}) \quad (7)$$

ou

$$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} - b_{t-1}) \quad (\text{aditivo}) \quad (8)$$

ℓ_t : Nível no tempo t.

α : Parâmetro de suavização do nível ($0 < \alpha < 1$).

Componente de Tendência:

$$b_t = \beta(\ell_t - \ell_{t-1}) + (1 - \beta)b_{t-1} \quad (9)$$

b_t : Taxa de mudança da tendência.

β : Parâmetro de suavização do nível ($0 < \beta < 1$).

Componente Sazonal:

$$s_t = \gamma \left(\frac{y_t}{\ell_{t-1}} \right) + (1 - \gamma)s_{t-m} \quad (\text{multiplicativo}) \quad (10)$$

ou

$$s_t = \gamma(\gamma_t - \ell_t) + (1 - \gamma)s_{t-m} \quad (\text{aditivo}) \quad (11)$$

s_t : Componente sazonal no tempo t .

γ : Parâmetro de suavização sazonal ($0 < \gamma < 1$)

m : Período sazonal.

Equação de Previsão:

$$\hat{\gamma}_{t+h|t} = (\ell_t + hb_t) \cdot s_{t+h-m(k)} \quad (\text{multiplicativo}) \quad (12)$$

ou

$$\hat{\gamma}_{t+h|t} = (\ell_t + hb_t) + s_{t+h-m(k)} \quad (\text{aditivo}) \quad (13)$$

ℓ_t : Nível no tempo t – Representa o valor médio subjacente da série no tempo t .

$\ell_t b_t$: Tendência no tempo t – Reflete a taxa de crescimento ou decrescimento da série.

$s_{t+h-m(k)}$: Componente sazonal – Captura da variação periódica repetitiva da série, ajustada para horizonte $t + h$ e deslocada para acomodar os ciclos sazonais (m é o período).

h : Horizonte de previsão Quantidade de passos à frente para os quais a previsão está sendo calculada.

m : Período sazonal – Número de períodos em um ciclo sazonal (por exemplo, 12 meses para dados mensais).

k : Índice de repetição sazonal – Relaciona o ciclo sazonal atual ao índice futuro.

Para o ajuste dos modelos ETS e ARIMA, foram considerados dados de 1996 a 2020 como treino e dados de 2021 a 2023 como teste. A adequação dos modelos foi avaliada por meio dos índices de desempenho descritos a seguir:

Raiz do Erro Médio Quadrático (RMSE)

Mede a magnitude média do erro entre os valores previstos e os valores reais. O RMSE pode ser escolhido, quando é desejável combinar as vantagens do MSE (Erro quadrático médio), na avaliação e expressar as métricas de avaliação na mesma unidade da variável alvo. Um valor menor de RMSE indica uma maior proximidade entre os valores previstos e os valores reais, sinalizando um desempenho superior do modelo (LIU; WANG, 2024). A fórmula é a seguinte:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

Erro Médio Absoluto Percentual (MAPE)

É calculado como a média do erro percentual entre os valores previstos e os valores reais. O valor do MAPE está entre 0 e o infinito positivo; quanto mais próximo de 0, mais precisa é a previsão. O MAPE pode ser escolhido, quando precisamos avaliar visualmente a precisão das previsões do modelo, pois ele expressa o erro como uma porcentagem, o que também significa que o MAPE pode ser usado ao comparar o desempenho relativo de diferentes conjuntos de dados (LIU; WANG, 2024). A fórmula é a seguinte:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (15)$$

Erro Absoluto Médio (MAE)

Assim como o MAE, a maioria dos modelos projetados para a tarefa LSTF (Previsão de Séries Temporais de Longa Sequência), nos mesmos conjuntos de dados de código aberto, consideram-no juntamente com o MSE (Erro Quadrático Médio). O MAE fornece uma maneira simples e fácil de entender para medir o desempenho geral dos modelos. O MAE calcula o erro absoluto entre o valor previsto e o valor real para cada amostra e divide a soma pelo número de amostras para obter o MAE (LIU; WANG, 2024). A fórmula é expressa como:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

O coeficiente de determinação (R^2) e o viés percentual (PBIAS) também foram usados na avaliação dos modelos:

$$R^2 = \frac{\frac{1}{n} \sum_{i=1}^n (M_i - \bar{M})(P_i - \bar{P})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (M_i - \bar{M})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (17)$$

$$PBIAS = \frac{\frac{1}{n} \sum_{i=1}^n (M_i - \bar{M})}{\sum_{i=1}^n M_i} \times 100\% \quad (18)$$

em que P_i e M_i são os valores previstos e medidos. O desempenho do modelo é considerado muito bom, quando, R^2 e PBIAS variam entre 0% e 5%, 0,9–1,0 e - 5%-5%, bom entre 5% e 10%, 0,8–0,9, e - 10%-10%, e aceitável entre 10% e 20%, 0,7–0,8 e - 20%-20% (Jorgensen et al., 2022; Patle et al., 2020; Moriasi et al., 2007).

Intervalos de confiança, um conceito introduzido pelo matemático e estatístico Jerzy Neyman, foram empregados para indicar o grau de incerteza associado a computações específicas. Embora o intervalo de confiança de 95% seja predominantemente utilizado, em trabalhos acadêmicos, o estudo também considerou níveis de confiança de 80%, 90% e 99%, reconhecendo que as variações podem depender do tamanho da amostra, nível de confiança desejado e variabilidade inerente ao estudo (Gouveia & Sousa, 2019).

Para avaliar como os valores atuais de temperatura e de precipitação estão relacionados com valores anteriores (Gao et al, 2024), foi calculada a função de autocorrelação mediante a função acf. Com finalidade de quantificar a correlação cruzada da temperatura e da precipitação com dados El Niño-Oscilação do Sul (Gushchina et al., 2020), no período avaliado de 1996-2023, foi utilizada a função ccf.

RESULTADOS E DISCUSSÃO

Pode ser verificado, na Tabela 1, que os modelos ETS e ARIMA apresentam desempenhos similares, em termos de RMSE e MAE para precipitação, com o ARIMA sendo ligeiramente superior no conjunto de treinamento e o ETS no conjunto de teste. No caso da temperatura, os valores de RMSE, MAE e MAPE são muito próximos para ambos os modelos. O coeficiente de determinação (R^2) indica um bom ajuste, nos conjuntos de treinamento, especialmente para temperatura, mas ambos os modelos apresentam uma significativa redução do R^2 , nos conjuntos de teste, sugerindo overfitting. O PBIAS mostra que os modelos de precipitação apresentam algum viés, enquanto os modelos de temperatura são menos viesados.

Ao contrastar as investigações de Areia-PB com as de Dimri et al. (2020), surgem disparidades notáveis na precisão do modelo. Para precipitação, a análise de Areia-PB revelou valores RMSE significativamente mais baixos (ARIMA: 0,24; ETS: 9,92) em comparação com Tehri (59,27) e Uttarkashi (57,428). Em termos de temperatura, o RMSE, para o modelo ARIMA Areia-PB (0,640486), foi menor que o relatado por Dimri et al. (1,5 para máximo e 1,4 para mínimo). A pesquisa brasileira ressaltou o domínio do modelo ARIMA, em relação ao ETS, produzindo consistentemente métricas de erro mais baixas. Embora ambos os estudos capturem efetivamente as tendências sazonais, eles diferem em seu foco em eventos climáticos extremos. Variações nas métricas de precisão podem resultar de discrepâncias climáticas, metodológicas ou de qualidade de dados regionais. Essas descobertas enfatizam a importância do contexto local e da seleção criteriosa de modelos na pesquisa climática, ilustrando como o desempenho pode variar significativamente em diferentes locais geográficos.

Tabela 1 - Métricas de acurácia para cada modelo

Modelo	Conjunto	Variável	RMSE	MAPE	MAE	R2	PBIAS
ETS	Treino	Precipitação	78,87	1,64	60,63	0,29	-6,1
ETS	Teste	Precipitação	37,96	1,99	26,89		34,34
ARIMA	Treino	Precipitação	76,87	1,4	57,52	0,32	-0,72
ARIMA	Teste	Precipitação	38,71	1,89	27,2	0,03	38,6
ETS	Treino	Temperatura	0,74	0,02	0,56	0,75	-0,02
ETS	Teste	Temperatura	0,73	0,02	0,6		1,63
ARIMA	Treino	Temperatura	0,74	0,02	0,55	0,75	-0,03
ARIMA	Teste	Temperatura	0,72	0,02	0,59	0,01	1,6

Fonte: Os autores, (2024).

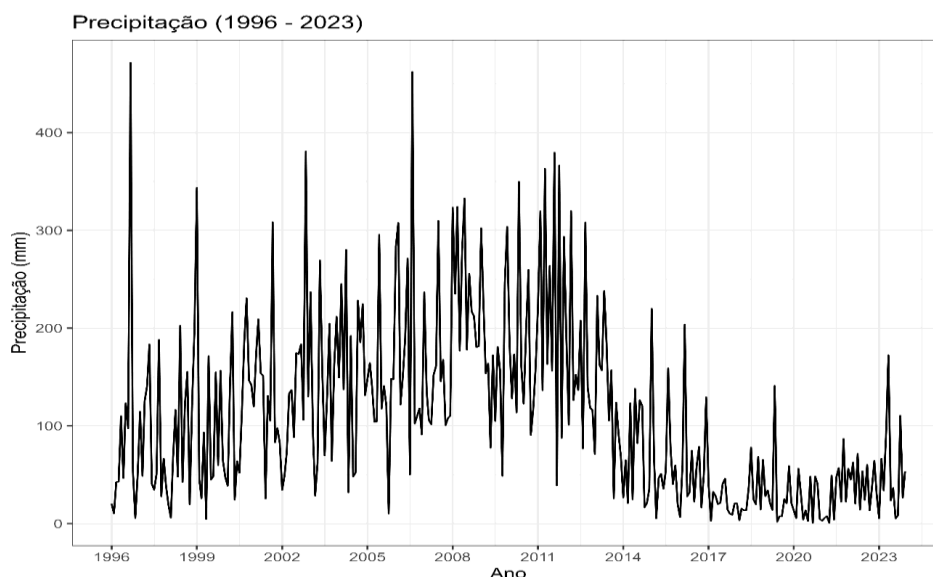
O exame da série temporal de precipitação de 1996 a 2023 indica alterações substanciais, nos padrões climáticos da região, conforme ilustrado na Figura 3. Nos primeiros anos considerados (1996-2008), episódios de chuvas significativas foram documentados, com níveis de precipitação superiores a 400 mm, corroborando com Pereira et al. (2015), em que foram observados altos volumes de precipitação, no período de 2004, indicando uma média de 2206 mm/ano, indicativos de anos caracterizados por umidade abundante. Entre 2008 e 2014, a região manteve volumes significativos de precipitação, com valores acima de 300 mm, alinhando-se os encontrados por Pereira et al. (2015), que observaram altos índices pluviométricos em 2011. No entanto, a partir de 2014, observou-se um declínio pronunciado nas chuvas, sugerindo o advento de um período prolongado de seca ou uma transformação nos padrões climáticos regionais, o que traz implicações diretas para as práticas agrícolas e a gestão dos recursos hídricos.

Por outro lado, a série temporal de temperatura exibe uma tendência contrastante, conforme ilustrado na Figura 4. No que se refere às variações de temperatura, o período de 1996 a 2005 apresentou médias situadas entre 24°C e 26°C, corroborando a tendência de aquecimento identificada por Pereira et al. (2015). Entre os anos de 2008 e 2014, verificou-se uma redução significativa, com mínimas próximas a 20°C registradas em 2011, o que contrasta parcialmente com o estudo mencionado, que havia apontado uma tendência de aumento gradual. A partir de 2014, observou-se um aumento constante das temperaturas, as quais ultrapassaram 24°C, chegando a picos de 26°C, alinhando-se com as projeções dos autores, que já haviam identificado os valores médios mais elevados entre 2012 e 2013.

De acordo com a Figura 5, a análise das funções de correlação cruzada entre precipitação e ENSO (Oscilação Sul) em Areia-PB, no período de 1996 a 2023, revelou interações temporais específicas ao longo do ano. Em agosto, identifica-se uma correlação negativa com meses de antecedência do evento ENSO, indicando uma possível supressão das chuvas. Outubro apresenta correlação positiva simultânea, sugerindo influência direta do ENSO, no aumento dos índices pluviométricos, enquanto novembro mostra correlação positiva com oito meses de defasagem, indicando resposta tardia ao

regime de chuvas. A maioria dos meses apresenta correções não significativas, com valores oscilando dentro do intervalo de ± 0.25 , sugerindo que o ENSO exerce influência limitada sobre o regime de chuva local. As correlações significativas encontradas são pontuais e moderadas, variando de -0.3 a 0.4, demonstrando que outros fatores climáticos podem ter maior relevância na variabilidade pluviométrica da região. Em estudo conduzido por Gushchina et al. (2020), eles encontraram resultados que mostram que o ENSO exerce influência significativa sobre as condições climáticas, em escalas globais e regionais, mas com diferenças marcantes. Em regiões tropicais úmidas e subúmidas, o ENSO impacta amplamente a precipitação e os índices de seca, com o El Niño associado a secas e a La Niña a condições mais úmidas. Esses efeitos são consistentes e lineares, com impactos mais intensos para o El Niño do Pacífico Oriental (EP) em comparação ao Pacífico Central (CP).

Figura 3 - Série Temporal da Precipitação Média (mm) em Areia-PB (1996-2023)




Fonte: Os autores, (2024).

A análise das correlações cruzadas entre o ENSO e dados de temperatura da Figura 6, ao longo dos 27 anos em Areia-PB, revelaram impactos significativos em momentos específicos do ano. Em observância aos meses de fevereiro, março e outubro, há influência direta do ENSO, no aumento das temperaturas (lag = 0), enquanto, em novembro, observa-se a redução térmica com cinco meses de defasagem (lag = 5). Nos demais meses, a influência é limitada. Portanto os resultados indicam que o ENSO tem papel relevante, mas pontual, na variabilidade térmica, devendo-se levar em consideração outros fatores climáticos tanto locais quanto regionais. Em pesquisas conduzidas Gao et al. (2020), seu estudo concluiu que o ENSO é um dos principais fatores que contribuem para a LTC (Correlação de Longo Prazo), nas séries temporais de anomalias de temperatura, especialmente nas regiões tropicais. A influência do ENSO foi claramente observada, nos padrões de correlação em longo prazo, destacando sua importância na variabilidade climática global.

A Figura 7 mostra a decomposição da série temporal de precipitação em seus componentes fundamentais: dados originais, resíduos, sazonalidade e tendência. Os dados originais são marcados por picos intermitentes significativos na precipitação. Os resíduos demonstram oscilações centradas em torno de zero, sem nenhum padrão discernível. A sazonalidade revela um ciclo anual consistente, caracterizado por oscilações regulares. A tendência indica um aumento inicial nos níveis de precipitação até aproximadamente 2010, seguido por um declínio gradual que se estende até 2020.

Figura 4 - Série Temporal da Temperatura Média (°C) em Areia-PB (1996-2023)



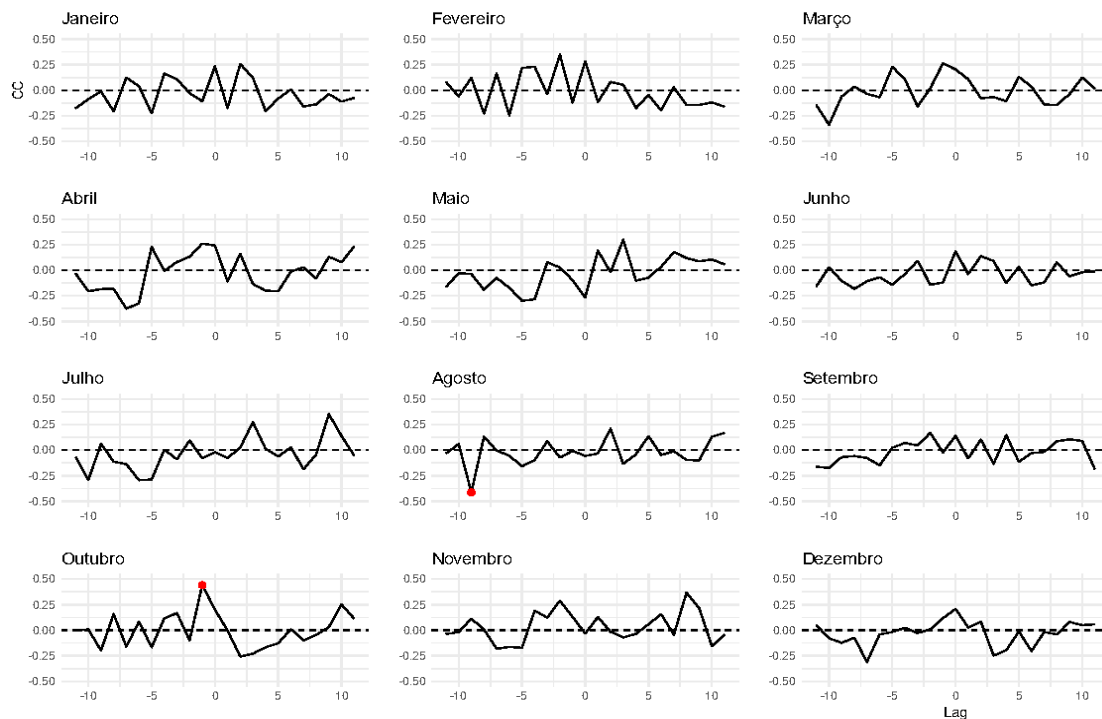
Fonte: Os autores, (2024).

A Figura 8 ilustra a decomposição da série temporal de temperatura. Os dados originais mostram variações notáveis com oscilações consistentes. Os resíduos exibem flutuações, em torno de zero, com magnitudes relativamente pequenas. A sazonalidade é evidenciada por meio de um ciclo anual estável. A tendência indica uma queda significativa até aproximadamente 2010, seguida por uma trajetória ascendente que se estende até 2020.

O exame dos boxplots de precipitação sazonal (Figura 9) e temperatura (Figura 10) elucida padrões meteorológicos distintos, porém complementares, na região analisada. A Figura 9 mostra uma sazonalidade pronunciada na precipitação, com o intervalo de maio a julho exibindo medianas elevadas (superiores a 200 mm) e considerável variabilidade, indicando assim a fase mais úmida. Por outro lado, os meses de outubro a dezembro demonstram precipitação mínima, raramente ultrapassando 50 mm. A presença de valores atípicos é predominante, durante a estação chuvosa, significando eventos de chuva excepcionalmente intensos. Simultaneamente, a Figura 10 mostra o regime térmico, destacando temperaturas elevadas de outubro a abril (média entre 24°C e 26°C) e condições mais temperadas de maio a setembro (média entre 20°C e 22°C). A variabilidade da temperatura permanece relativamente estável, ao longo do ano, com uma flutuação anual de temperatura de aproximadamente 4°C a 6°C. Uma correlação inversa é evidente entre os fenômenos ilustrados nas duas figuras: os meses caracterizados pela maior precipitação, na Figura 9, geralmente coincidem com temperaturas mais baixas, na Figura 10, enquanto os meses mais secos se alinham com as leituras térmicas mais altas.

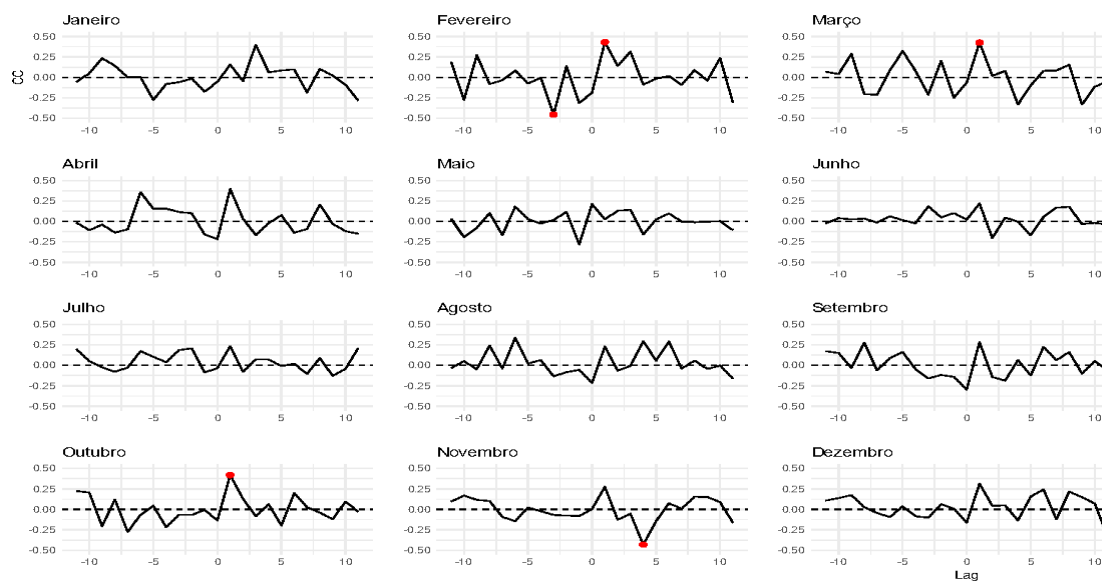
A Figura 11 ilustra a Função de Autocorrelação (ACF) da série temporal de precipitação, respectivamente. As autocorrelações são marcadamente elevadas e exibem um declínio gradual, indicando uma correlação significativa entre os valores de precipitação temporalmente próximos. Essa observação implica que os modelos ARIMA podem ser aplicáveis à modelagem dessa série temporal.

Figura 5 - Correlação Cruzada da Precipitação (mm) com El Niño-Oscilação Sul (ENSO) em Areia (1996-2023)



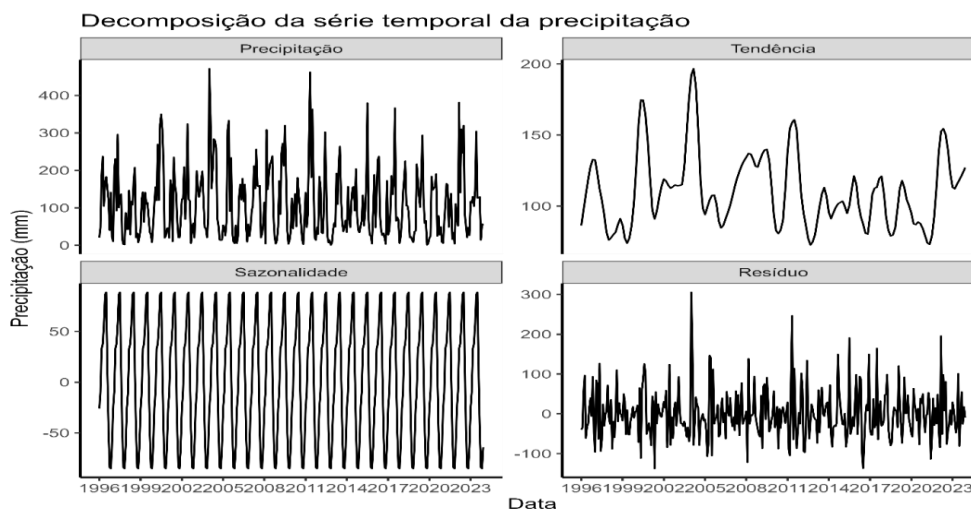
Fonte: Os autores, (2024).

Figura 6 - Correlação Cruzada da Temperatura (°C) com El Niño-Oscilação Sul (ENSO) em Areia (1996-2023)




Fonte: Os autores, (2024).

Figura 7 - Decomposição da Precipitação em Areia-PB (1996-2023)



Fonte: Os autores, (2024).

Figura 8 - Decomposição da Temperatura em Areia-PB (1996-2020)

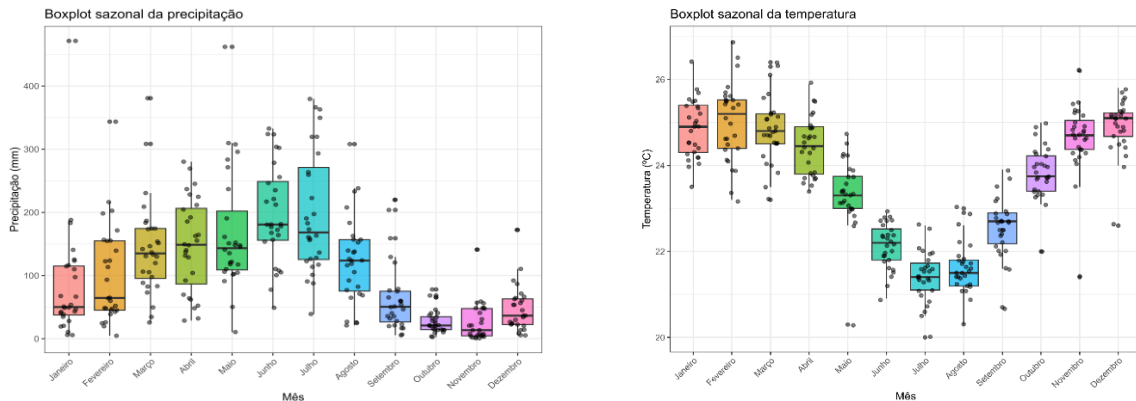


Fonte: Os autores, (2024).

A Figura 12 mostra a previsão de precipitação para o período 2021-2023 empregando um modelo ARIMA sazonal (1.1.2) (1.0.1). As previsões sugerem uma tendência de estabilização dos níveis de precipitação, em valores relativamente baixos, caracterizados por flutuações mínimas ou picos pronunciados.

A Figura 13 mostra a previsão de precipitação para o período 2021-2023 empregando um modelo ETS. As previsões sugerem uma tendência de estabilização dos níveis de precipitação, em valores relativamente baixos, caracterizados por flutuações mínimas ou picos pronunciados.

Figuras 9 e 10 - Boxplot sazonal da Precipitação (mm) e da Temperatura (°C) ao longo dos meses do ano



Fonte: Os autores, (2024).

A Figura 14 mostra o ACF da série temporal de temperatura. As autocorrelações são substanciais e diminuem progressivamente, permanecendo significativas nas defasagens iniciais. Essa observação indica uma dependência temporal direta robusta dentro da série de temperatura, sugerindo que modelos autorregressivos (AR) de baixa ordem podem que ser adequados.

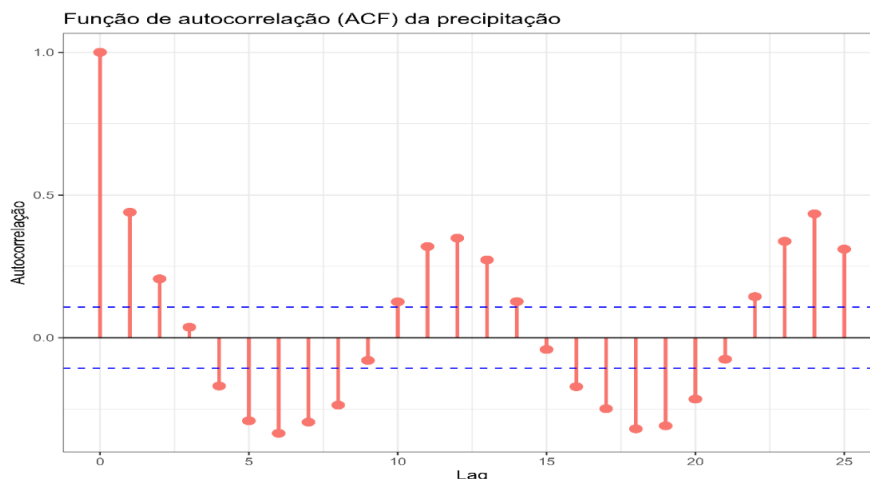
A Figura 15 apresenta a previsão de temperatura para 2021-2023 utilizando um modelo ARIMA (Média Móvel Integrada Autoregressiva). Para o período projeto, de 2021 a 2023, prevê a continuidade do aumento das temperaturas do aumento das temperaturas, estabilizando-se e acima de 24°C. Balasmeh et al. (2019) validaram os modelos ARIMA, para previsões de precipitação, que se estendem até 2026, revelando uma tendência caracterizada pela diminuição das chuvas fortes e um aumento na precipitação normal. Ayo et al. (2021) recomendaram o modelo ARIMA para prever a atenuação da chuva. Gowri et al. (2022) demonstraram que o modelo ETS supera os modelos ARIMA na precisão da previsão de temperatura.

De acordo com Dimri et al. (2020), um exame das séries temporais de precipitação, nas estações de monitoramento de Tehri e Uttarkashi, indica que os maiores volumes de chuva são registrados, durante os meses de julho e agosto, com picos de 692,64 mm, na estação de Tehri e 663,45 mm, na estação Uttarkashi, observados em julho de 1936. Os autores notaram precipitação mínima ou ausente, nos meses de novembro e dezembro, em ambas as estações, com a queda de neve mais significativa ocorrendo em fevereiro e março.

A Figura 16 apresenta a previsão de temperatura para 2021-2023 utilizando um modelo ETS (Erro, Tendência e Sazonalidade). As previsões implicam a persistência de um aumento gradual da temperatura média, estabilizando-se em torno de valores ligeiramente superiores a 24°C.


Dimri et al. (2020) investigaram ainda mais as flutuações de temperatura, nas estações de Tehri e Uttarkashi, observando variações consideráveis. Em Tehri, a temperatura máxima variou de 39,64° C a 13,86° C, enquanto a mínima variou de 26,16° C a 0,86° C. Por outro lado, em Uttarkashi, as temperaturas máximas oscilaram entre 31,13° C e 8,24° C e as mínimas entre 20,05° C e -2,42° C. Os pesquisadores discerniram uma variação sazonal distinta, na precipitação e na temperatura, com picos de chuvas, durante a estação das monções e níveis mínimos no inverno, enquanto as temperaturas máximas ocorrem no verão e as mínimas no inverno.

Figura 11 - Função de Autocorrelação (ACF) da série temporal de precipitação



Fonte: Os autores, (2024).

Figura 12 - Previsão de Precipitação (1996-2023) – Modelo ARIMA




Fonte: Os autores, (2024).

Os modelos preditivos, conforme descrito por Dimri et al. (2020), refletem as tendências locais e a dinâmica sazonal, embora com uma representação mais moderada em razão das metodologias de processamento de dados. Os resultados revelaram uma tendência consistente nos níveis de precipitação. Em relação à temperatura, uma tendência de aumento foi observada para os valores mínimos e um ligeiro aumento, para os máximos em Tehri, enquanto, em Uttarkashi, uma tendência de queda foi evidente para as temperaturas mínima e máxima. Essas discrepâncias nas tendências entre as estações ressaltam a natureza intrincada e a variabilidade localizada dos padrões climáticos na região examinada.

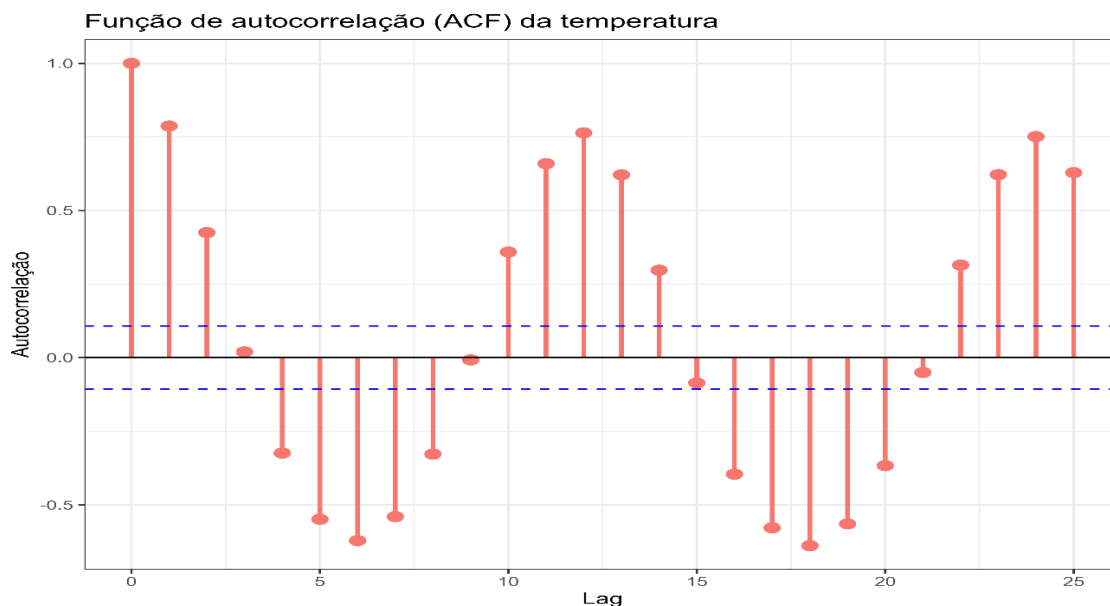
Conforme observado por MARENGO, CUNHA e ALVES (2016), os indicadores de seca começaram, no Nordeste do Brasil, em dezembro de 2011, exacerbando-se, durante o verão e o outono de 2012, com intensidade e repercussões sem precedentes, em várias décadas, resultando em significativa escassez de água em quase toda a região semiárida.

Figura 13 - Previsão de Precipitação (1996-2023) – Modelo ETS




Fonte: Os autores, (2024).

Figura 14 - Função de Autocorrelação (ACF) da série temporal da temperatura




Fonte: Os autores, (2024).

Figura 15 - Previsão de Temperatura (1996-2023) – Modelo ARIMA



Fonte: Os autores, (2024).

Figura 16 - Previsão da Temperatura (1996-2023) – Modelo ETS



Fonte: Os autores, (2024).

Na pesquisa realizada em Areia-PB, a notável sazonalidade também foi evidente, na precipitação e na temperatura, empregando modelos ARIMA para análise e previsão. Em Areia-PB, um declínio significativo na precipitação foi observado, após 2010, juntamente com um aumento gradual na

temperatura, com previsões sugerindo uma estabilização em níveis mais baixos de precipitação e um aumento sustentado na temperatura.

Em contraste, Dimri et al. (2020) relataram flutuações de temperatura mais pronunciadas em Tehri e Uttarkashi, com tendências divergentes observadas entre as estações. O estudo em Areia-PB concluiu que o modelo ARIMA superou o ETS em precisão preditiva, enquanto os autores enfatizaram predominantemente seu foco nas metodologias ARIMA.

CONSIDERAÇÕES FINAIS

A análise das séries temporais de precipitação e temperatura em Areia-PB, no período de 1996 a 2023, revelou mudanças significativas nos padrões climáticos da região. Nos anos posteriores a 2010, observou-se um declínio notável nos níveis de precipitação, acompanhado por um aumento progressivo nas temperaturas, fornecendo evidências convincentes dos impactos das mudanças climáticas nesta área geográfica específica.

A eficácia demonstrada dos modelos preditivos ARIMA e ETS na previsão de dados climáticos ressalta a importância dessas ferramentas analíticas para o planejamento agrícola e o gerenciamento de recursos hídricos, especialmente em um contexto de crescente incerteza climática.

Este estudo enfatiza a necessidade de monitoramento contínuo do clima e atualização regular dos modelos empregados, garantindo que as previsões climáticas permaneçam as mais precisas possíveis. Essa abordagem sistemática não apenas contribui para o campo da climatologia regional, mas também oferece benefícios diretos às comunidades locais, fornecendo informações valiosas para a gestão sustentável dos recursos naturais e a resiliência das práticas agrícolas diante dos desafios ambientais em curso.

REFERÊNCIAS

- AL BALASMEH, O.; BABBAR, R.; KARMAKER, Tapas. Trend analysis and ARIMA modeling for forecasting precipitation pattern in Wadi Shueib catchment area in Jordan. **Arabian Journal of Geosciences**, v. 12, n. 27, 2019. DOI: <https://doi.org/10.1007/s12517-018-4205-z>.
- ALBUQUERQUE, R. C. Modelagem de séries temporais aplicados a dados climatológicos no sertão paraibano. 2015. **Trabalho de Conclusão de Curso** – Universidade Estadual da Paraíba. 35 p.
- ASADI, M.; KARAMI, M. Modeling of relative humidity trends in Iran. **Modeling Earth Systems and Environment**, v. 8, p. 1035-1045, 2021. <https://doi.org/10.1007/s40808-021-01093-9>.
- ASSAD, E. D.; VICTORIA, D. D. C.; CUADRA, S. V.; PUGLIERO, V. S.; ZANETTI, M. R. **Efeito das mudanças climáticas na agricultura do Cerrado**. In: BOLFE, E. L.; SANO, E. E.; CAMPOS, S. K. (Eds.). **Dinâmica Agrícola no Cerrado: análises e projeções**. Brasília, DF: Embrapa, 2020. p. 213-228.
- ASSIS, ERICA; ZAMPIERI, HENRIQUE. Os impactos das mudanças climáticas na agropecuária brasileira de 2015 a 2020. 2021. Artigo Científico (Ciências Sociais Aplicadas). Orientador: Gilberto Fernandes da Costa. **Repositório Anima Educação**. Disponível em: <https://repositorio.animaeducacao.com.br/handle/ANIMA/20655>. Acesso em: 03 out. 2024.
- AYO, A. O.; OWOLAWI, P. A.; OJO, J. S. Performance of ARIMA modelling on sub-tropical rain attenuation at Ka-band terrestrial link in Kwazulu-Natal, South Africa. In: **IEEE INTERNATIONAL CONFERENCE ON MICROWAVES, ANTENNAS, COMMUNICATIONS AND ELECTRONIC SYSTEMS (COMCAS)**, 2021. Anais [...]. IEEE, 2021. DOI: [10.1109/COMCAS52219.2021.9629001](https://doi.org/10.1109/COMCAS52219.2021.9629001).
- BABAZADEH, H.; SHAMSANIA, S. A. Assessment of drought and climate change in the Sistan plain of Iran using remote sensing and artificial neural network modeling. **International Journal of Climatology**, v. 34, n. 11, p. 3111-3122, 2014.
- BALIBEY, M.; SERPIL, D. Analysis of drought in Turkey using the standardized precipitation index (SPI) and artificial neural networks. **Natural Hazards**, v. 75, n. 2, p. 2135-2148, 2015.

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

CHENG, L. et al. Continues Record Global Ocean Warming. **Advances in Atmospheric Sciences**, v. 36, n. 3, p. 249-252, 2019. <https://doi.org/10.1007/s00376-019-8276-x>.

DANTAS, L. G. Aplicação de modelos para séries temporais e pluviométricas no Estado da Paraíba. 2016. 118 f. **Dissertação** (Mestrado em Meteorologia) – Programa de Pós-Graduação em Meteorologia, Centro de Tecnologia e Recursos Naturais, Universidade Federal de Campina Grande, Paraíba, Brasil, 2016. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/1390>.

DIMRI, T.; AHMAD, .SHARIF, M. Time series analysis of climate variables using seasonal ARIMA approach. **Journal of Earth System Science**, v. 129, p. 149, 2020. Disponível em: <https://doi.org/10.1007/s12040-020-01408-x>. Acesso em: 4 set. 2024.

FEIJÓ, C. Conceitos básicos de séries temporais para modelagem macroeconômica. Material de apoio à aula de RBC, Curso Macroeconomia Avançada, Universidade Federal Fluminense, 2014. Disponível

em:http://www.ppgge.uff.br/images/revisão_básica_séries_temporais_material_de_apoio_curso_teorias_macroeconomica_PPGE_UFF.pdf. Acesso em: 23 jul. 2024.

GAO, M.; FANG, X.; GE, R.; FAN, Y.; WANG, Y. Multiple serial correlations in global air temperature anomaly time series. **PLoS ONE**, v. 19, n. 7, p. e0306694, 2024. Disponível em: <https://doi.org/10.1371/journal.pone.0306694>. Acesso em: 4 jan. 2025.

GOUVEIA, R.; SOUSA, S. Significado de Intervalo de Confiança. [2019]. Disponível em: <https://www.significados.com.br/intervalo-de-confianca/>. Acesso em: 23 jul. 2024.

GOWRI, L.; MANJULA, K. R.; SASIREKA, K.; DEEPA, D. Assessment of Statistical Models for Rainfall Forecasting Using Machine Learning Technique. **Journal of Soft Computing in Civil Engineering**, v. 6, n. 2, p. 51-67, 2022. <https://doi.org/10.22115/SCCE.2022.304260.1363>.

GUSHCHINA, D.; ZHELEZNOVA, I.; OSIPOV, A.; OLCHEV, A. Effect of various types of ENSO events on moisture conditions in the humid and subhumid tropics. **Atmosphere**, v. 11, n. 12, p. 1354, 2020. Disponível em: <https://doi.org/10.3390/atmos11121354>. Acesso em: 4 jan. 2025.

HYNDMAN, R. J.; KOHLER, A. B.; ORD, J. K.; SNYDER, R. D. **Forecasting with exponential smoothing: the state space approach**. Berlin: Springer-Verlag, 2008. 362 p. Disponível em: <https://link.springer.com/book/10.1007/978-3-540-71918-2>. Acesso em: 03 out. 2024.

IBGE – Instituto Brasileiro de Geografia e Estatística. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/pb.html>. Acesso em: 23 jul. 2024.

JØRGENSEN, S. E.; FATH, B. D.; NIELSEN, S. N. Modelling the Environmental Ecosystem for Sustainable Development. **Ecological Modelling**, 2022. Disponível em: <https://doi.org/10.1016/j.ecolmodel.2022.111248>.

KRZYSZCZAK, J. et al. Analysis of Climate Dynamics Across a European Transect Using a Multifractal Method. In: ROJAS, I.; POMARES, H.; VALENZUELA, O. (Ed.). **Advances in Time Series Analysis and Forecasting**. Cham: Springer International Publishing, 2017. Disponível em: https://doi.org/10.1007/978-3-319-55789-2_8.

LIU, X.; WANG, W. Deep Time Series Forecasting Models: A Comprehensive Survey. **Mathematics**, v. 12, n. 1504, p. 1-33, 2024. DOI: [10.3390/math12101504](https://doi.org/10.3390/math12101504).

MACHEKPOSHTI, H. K. et al. Modelling Climate Variables of Rivers Basin Using Time Series Analysis (Case Study: Karkheh River Basin at Iran). **Civil Engineering Journal**, v. 4, n. 1, p. 78-92, 2018.

MARENGO, A. J.; CUNHA A. P.; ALVES L. M. **A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico**. Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), São Paulo, Brasil, Centro de Ciências do Sistema Terrestre – Instituto Nacional de Pesquisas Espaciais (CCST/INPE), São Paulo, Brasil, 2016.

MAKRIDAKIS, S.; HYNDMAN, R. J.; PETROPOULOS, F. Forecasting in social settings: the state of the art. **International Journal of Forecasting**, v. 36, n. 1, p. 15–28, 2020. DOI: [10.1016/j.ijforecast.2019.05.011](https://doi.org/10.1016/j.ijforecast.2019.05.011).

- MEDEIROS, S. D. S. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas na Região Nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 9, p. 247-255, 2005.
- MIRANDA, R. G. Espaço admissível para os parâmetros do modelo de suavização exponencial com dupla sazonalidade aditivo. 2009. **Tese** (Doutorado em Engenharia de Produção) – Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, 2009.
- MOHAMED, N.; AHMAD, M. H.; ISMAIL, Z.; SUHARTONO, S. Short term load forecasting using double seasonal ARIMA model. **Regional Conference on Statistical Sciences**, 2010.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blucher, 2006. 538 p.
- 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. **Transactions of the ASABE**, 2007. Disponível em: <https://doi.org/10.13031/2013.23153>.
- PEREIRA, A. R.; COSTA, A. S.; OLIVEIRA, V. G.; BORGES, P. F.; FILHO, A. I. Análise do comportamento das médias anuais da precipitação pluvial e temperatura da cidade de Areia, Paraíba. **Gaia Scientia**, v. 9, n. 1, p. 67-73, 2015. ISSN 1981-1268.
- PATLE, G. T.; LAXMAN, R. H.; DATTA, S. K. A novel assessment of water stress in diverse cropping patterns. **Agricultural Water Management**, 2020. Disponível em: <https://doi.org/10.1016/j.agwat.2020.106134>.
- RAD, M. R. N. et al. Seasonal Autoregressive Integrated Moving Average (SARIMA) for Melon (Cucumis melo) Yield from 2011 to 2020 Based on Planting Date Period. **Current Agriculture Research Journal**, v. 11, n. 3, p. 753-760, 2023. <https://doi.org/12944/CARJ.11.3.06>.
- R CORE TEAM. **R: A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.R-project.org/>. Acesso em: 01 out. 2024.
- SATO, R. C. Gerenciamento de doenças utilizando séries temporais com o modelo ARIMA. **Einstein**, v. 11, n. 1, 2013. <https://doi.org/10.1590/S1679-45082013000100024>.

Recebido em: 07/10/2024
Aceito para publicação em: 21/01/2025