Revista Brasileira de Climatologia
Brazilian Journal of Climatology
OPEN ACCESS

ANÁLISE DA VARIABILIDADE PLUVIOMÉTRICA NA CAATINGA PARAIBANA E SUA RELAÇÃO COM VARIÁVEIS OCEÂNICAS

Analysis of rainfall variability in the Caatinga of Paraíba and its relationship with oceanic variables

Análisis de la variabilidad de las precipitaciones en la región de la Caatinga de Paraíba y su relación con las variables oceánicas

Bruce Kelly da Nobrega Silva
Núcleo de Desertificação e Agroecologia, Instituto Nacional do Semiárido – INSA
Campina Grande, PB, Brasil
bruce.silva@pesquisa.insa.gov.br

Djailson Silva da Costa Júnior
Programa de Pós-graduação em Ciências Agrária, Universidade Federal do Piauí – UFPI
Bom Jesus, PI, Brasil
djailson.junior@ufpi.edu.br

John Cunha
Centro de Recursos Naturais e Tecnologia, Universidade Federal de Campina Grande – UFCG
Campina Grande, PB, Brasil
john.elton@professor.ufcg.edu.br

Aldrin Martin Pérez-Marin
Núcleo de Desertificação e Agroecologia, Instituto Nacional do Semiárido – INSA
Campina Grande, PB, Brasil
aldrin.perez@insa.gov.br

Resumo: As mudanças climáticas intensificam a variabilidade da precipitação e a frequência de eventos extremos, impactando severamente regiões com recursos hídricos limitados. No Semiárido brasileiro, essa mudança representa um desafio crítico devido à irregularidade das chuvas e à alta vulnerabilidade socioambiental do bioma Caatinga. A análise de séries temporais é essencial para delinear tendências, padrões sazonais e anomalias climáticas, fornecendo base para estratégias de adaptação. Estudos anteriores atestam que a variabilidade interanual no Semiárido é fortemente modulada por teleconexões oceano-atmosfera, como o El Niño-Oscilação Sul (ENOS) e o Dipolo do Oceano Atlântico Sul (SAODI). Indicadores como o Índice de Anomalia de Chuva (IAC) e o Índice Oceânico do Niño (ONI) são cruciais para o monitoramento sazonal de períodos secos e úmidos. Este estudo analisou a série temporal de precipitação (2011–2025) da área experimental do INSA em Campina Grande, PB, Brasil, objetivando identificar tendências, caracterizar anomalias e avaliar suas correlações com os principais indicadores climáticos. A metodologia incluiu o teste de Mann-Kendall, o estimador de Sen e a modelagem SARIMA. Os resultados indicam uma tendência estatisticamente significativa de aumento gradual na precipitação mensal (+0,106 mm/mês) e confirmam a modulação das anomalias: correlação negativa do IAC com o ONI (El Niño associado à seca) e uma correlação sazonal variável com o SAODI, que se apresenta positiva no verão e em alguns meses do outono e primavera, mas predominantemente negativa no inverno.

Palavras-chave: SARIMA, tendência, ENOS, SAODI, mudanças climáticas.

Abstract: Climate change intensifies precipitation variability and the frequency of extreme events, severely impacting regions with limited water resources. In the Brazilian Semi-Arid region, this change poses a critical challenge due to rainfall irregularity and the high socio-environmental vulnerability of the Caatinga biome. Time series analysis is essential to delineate trends, seasonal patterns, and climate anomalies, providing a basis for adaptation strategies. Previous studies attest that interannual variability in the Semi-Arid region is strongly modulated by ocean-atmosphere teleconnections, such as the El Niño-Southern Oscillation (ENSO) and the South Atlantic Ocean Dipole (SAODI). Indicators such as the Rainfall Anomaly Index (RAI) and the Oceanic Niño Index (ONI) are crucial for the seasonal monitoring of dry and wet periods. This study analyzed the precipitation time series (2011–2025) from the INSA experimental area in Campina Grande, PB, Brazil, aiming to identify trends, characterize anomalies, and evaluate their correlations with the main climate indicators. The methodology included the Mann-Kendall test, Sen's slope estimator, and SARIMA modeling. The results indicate a statistically significant trend of a gradual increase in monthly precipitation (+0.106 mm/month) and confirm the modulation of the anomalies: a negative correlation between the RAI and the ONI (El Niño associated with drought) and a variable seasonal correlation with the SAODI, which is positive during summer and some months of autumn and spring, but predominantly negative in winter.

Keywords: SARIMA, tendency, ENSO, SAODI, climate change.

Resumen: El cambio climático intensifica la variabilidad de la precipitación y la frecuencia de eventos extremos, impactando severamente a las regiones con recursos hídricos limitados. En el Semiárido brasileño, este cambio plantea un desafío crítico debido a la irregularidad de las lluvias y a la alta vulnerabilidad socioambiental del bioma Caatinga. El análisis de series de tiempo es esencial para delinear tendencias, patrones estacionales y anomalías climáticas, proporcionando una base para las estrategias de adaptación. Estudios previos atestiguan que la variabilidad interanual en el Semiárido está fuertemente modulada por teleconexiones océano-atmósfera, como El Niño-Oscilación del Sur (ENOS) y el Dipolo del Océano Atlántico Sur (SAODI). Indicadores como el Índice de Anomalía de Precipitación (RAI) y el Índice Oceánico del Niño (ONI) son cruciales para el monitoreo estacional de los períodos secos y húmedos. Este estudio analizó la serie temporal de precipitación (2011–2025) del área experimental del INSA en Campina Grande, PB, Brasil, con el objetivo de identificar tendencias, caracterizar anomalías y evaluar sus correlaciones con los principales indicadores climáticos. La metodología incluyó la prueba de Mann-Kendall, el estimador de Sen y el modelado SARIMA. Los

resultados indican una tendencia estadísticamente significativa de aumento gradual en la precipitación mensual (+0,106 mm/mes) y confirman la modulación de las anomalías: una correlación negativa entre el RAI y el ONI (El Niño asociado con sequía) y una correlación estacional variable con el SAODI, que se presenta positiva en verano y en algunos meses de otoño y primavera, pero predominantemente negativa en invierno.
Palabras clave: SARIMA, tendencia, ENOS, SAODI, cambio climático.

Submetido em: 19/03/2025
Aceito para publicação em: 03/05/2026
Publicado em: 24/07/2026

1. INTRODUÇÃO

Evidências que indicam que as mudanças climáticas intensificam a variabilidade da precipitação, resultando em eventos extremos mais frequentes. Essas alterações hidroclimáticas têm o potencial de gerar impactos socioecológicos significativos, especialmente em áreas caracterizadas por recursos hídricos limitados. Os cenários de mudanças climáticas apontam para uma redução significativa da precipitação durante o período chuvoso da região Nordeste indicando uma projeção de acentuado déficit de chuvas acumulada anual para a região até o final do século (Costa et. al., 2020).

Estudos no Semiárido brasileiro revelam uma tendência de aumento na frequência, duração e severidade das secas nas últimas décadas, acompanhada por uma extrema variabilidade interanual modulada pelas temperaturas dos oceanos, resultando em déficits hídricos cada vez mais severos (Brito et al., 2018). No Nordeste brasileiro, pesquisas demonstram que a região tem enfrentado secas excepcionalmente severas e prolongadas, com reduções significativas nos volumes anuais de precipitação (chegando a 50% abaixo da média em anos críticos), impulsionadas por um aumento na temperatura regional e intensa variabilidade interanual (Marengo et al., 2017).

Análises de longo prazo das séries temporais no Nordeste do Brasil indicaram tendências estatisticamente significativas de diminuição da precipitação em diversas estações meteorológicas, evidenciando uma alta variabilidade espaço-temporal e maior vulnerabilidade climática na região (Silva, 2004). A análise de séries temporais de precipitação é uma das ferramentas essenciais para a área da meteorologia, pois permite identificar possíveis padrões climáticos, eventos extremos e fornecer informações para tomadas de decisões em diversos segmentos. Essa abordagem aliada a indicadores climáticos e oceânicos contribui significativamente para mitigar os impactos ocasionados pelos eventos climáticos extremos e de desenvolver estratégias de adaptação nos variados biomas.

A Caatinga, um bioma de clima semiárido endêmico do Brasil, enfrenta desafios consideráveis devido às irregularidades das chuvas. Compreender então os padrões da precipitação neste bioma é essencial para garantir a segurança hídrica, proteger sua biodiversidade e promover o desenvolvimento sustentável das comunidades locais. A identificação de tendências climáticas é especialmente relevante em regiões vulneráveis como a Caatinga, conforme enfatizado por Gutiérrez et al. (2014).

Estudos prévios ressaltam a importância da análise de séries temporais para detectar tendências e padrões na precipitação ao longo do tempo. Marengo et al. (2017) demonstraram que, a região do semiárido nordestino tem apresentado uma variabilidade interanual significativa na precipitação, fortemente influenciada por fenômenos como o El Niño-Oscilação Sul (ENOS). Adicionalmente, Sivakumar et al. (2005) destacaram a sensibilidade das regiões áridas e semiáridas, como a Caatinga, às flutuações na precipitação, com impactos diretos na produtividade agrícola e na disponibilidade de água. A análise da variabilidade da chuva em diferentes escalas espaciais e temporais é extremamente relevante para a sociedade como um todo, pois a precipitação pluvial é um componente fundamental do sistema climático.

Muitos índices climáticos são construídos e adaptados constantemente, com objetivo de caracterizar uma região climatológica ou socialmente. A partir desses argumentos, o Índice de Anomalia de Chuva (IAC) pode ser uma ferramenta eficiente para a caracterização climática de uma região, e também um método viável de alerta e prevenção de consequências negativas intensas, relacionadas a eventos de desastres ambientais (Pinto et al., 2025).

As anomalias de temperatura no oceano são diretamente responsáveis pela qualidade da estação chuvosa em determinadas áreas ou regiões do globo, no caso do semiárido brasieiro nordestino o El Niño (La Niña). O índice que revela a intensidade do El Niño é conhecido como Oceanic Niño Index (ONI). Outro índice que está relacionado a qualidade da estação chuvosa do NEB é o South Atlantic Ocean dipole Index (SAODI) que é definido por Nmanchi et al., (2011) e obtido no setor nordeste do Atlântico Sul, 10°E–20°W, 0°–15°S, e para o setor subtropical,10°–40°W, 25°S–40°S.

A análise aprofundada de séries temporais de precipitação e índices climáticos, além de permitir a compreensão das mudanças climáticas regionais, é crucial para embasar a formulação de políticas públicas direcionadas à conservação e ao uso sustentável dos recursos naturais, principalmente para regiões semiáridas. Dias et al., (2022) utilizou o IAC para para avaliar como ferramenta de caracterização de climatológica e alerta de possíveis áreas de risco na cidade de Marabá no sudeste do Pará.

Dos Santos et al., (2019) utilizaram o Índice de Precipitação Normalizada (SPI) para identificar e quantificar eventos secos e chuvosos, os dados de precipitação foram das estações do Centro de Previsão de Tempo e Estudos Climáticos e A precipitação estimada

pelo Climate Hazards Group InfraRed Precipitation with Stations (CHIRPS), cujo período foi de 1999 à 2017 além de utilizar variáveis oceânicas e atmosféricas para caracaterizar médias e anômalaias do sistema oceano-atmosfera e associá-los ao padrão espaço temporal da precipitação para no Nordeste Brasileiro (NEB).

Além disso, investigações como a de Dimri et al. (2020), que aplicaram modelos de séries temporais (SARIMA) para prever padrões climáticos na bacia do rio Bhagirathi, na Índia, evidenciam a utilidade de tais abordagens para aprimorar práticas de gestão hídrica em contextos semelhantes. Estas informações de padrão e tendências podem ajudar como uma ferramenta de previsão para o desenvolvimento de melhores práticas de gerenciamento de água na área. A Caatinga, apesar de sua importância ecológica e social, ainda apresenta lacunas significativas em relação à compreensão de suas dinâmicas pluviométricas. A falta de modelos robustos para previsão sazonal de precipitação e os impactos insuficientemente explorados das flutuações de chuvas sobre a biodiversidade e a agricultura destacam a necessidade destes estudos. Este estudo tem como objetivo principal analisar a série temporal de precipitação em uma área preservada da Caatinga paraibana, visando identificar tendências, padrões sazonais e anomalias climáticase avaliar a relação com indicadores climáticos.

2. MATERIAL E MÉTODOS

2.1 Localização e Caracterização da Área Experimental.

A infraestrutura da torre de 15m está na área experimental do Instituto Nacional do Semiárido (INSA), no município de Campina Grande - PB, nas coordenadas (35,979°S; -7,272°E; 486,8 m) (Figura 1). Os principais equipamentos são: sistemas de correlação turbulenta, sensores de temperatura e umidade do solo, sensor de radiação e pluviômetro. Segundo Costa Júnior et al. (2024) a vegetação é formada por florestas semidecíduas, composta por espécies arbustivas-lenhosas, com a ocorrência de espécies típicas cuja caraterística é perder as folhas na estação seca.

O tipo de solo dominante é o neossolo litólico, caracterizado como raso, atingindo profundidade máxima de 10 cm, com drenagem moderada a imperfeita, pedregosidade excessiva e relevo plano a suave ondulado (EMBRAPA, 2013). De acordo com a classificação de Köppen, o clima da região é semiárido, Tipo BSh (Alvares et al., 2013). A estação chuvosa

ocorre entre fevereiro e agosto. A precipitação total anual é de 764 mm, sendo os meses mais chuvosos entre abril e julho (AESA, 2023). As médias anuais de temperatura e umidade são de 22,2°C e 83,1%, respectivamente, segundo dados do Instituto Nacional de Meteorologia (INMET, 2023) para o período de 1961 a 2020 para o município de Campina Grande-PB.

Figura 1 - Localização da torre micrometeorológica na área experimental do INSA em Campina Grande-PB.

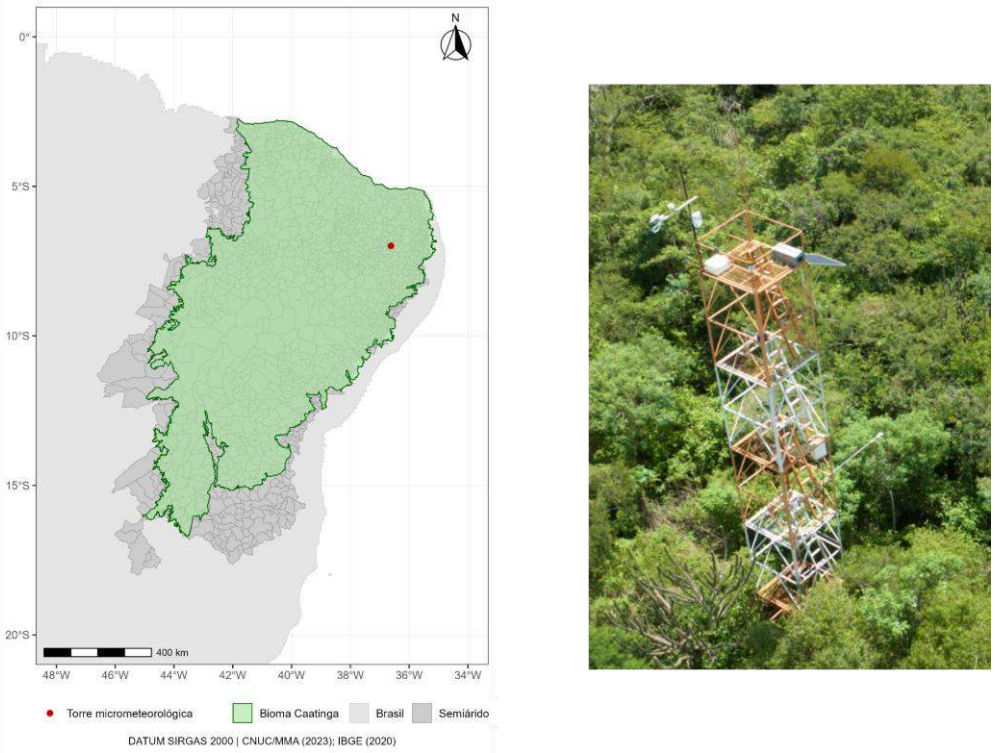

2.2 Procedimentos metodológicos.

A variabilidade mensal dos dados de precipitação entre 2011 a 2025 foi avaliada por medidas de tendência central, medidas de dispersão, para cada mês do período citado, todas as análises e figuras foram utilizando o software R. A tendência foi avaliada pelo teste não paramétrico de Mann-Kendall (MK) que é utilizado por vários estudos ambientais (Da Silva 2020; Holender e Santos., 2023). o teste realiza uma verificação sequencial dos dados da série temporal, contabiliza-se o número de vezes que os valores posteriores superam o valor da precipitação. De acordo com (Júnior e Lucena (2021) a equação é dada por:

$$S = \sum_{i=2}^{n} \sum_{j=2}^{i=1} sinal\,(p_j - p_i) \qquad (1)$$

em que S é o total das contagens de (p_j-p_i); p_j é o valor inicial após p_i, n é o número de dados da série temporal. Para cada par de dados são atribuídos os seguintes Valores:

$$Sinal = \begin{cases} +1 \; se \; (x_j - x_i) > 0 \\ 0 \; se \; (x_j - x_i) = 0 \\ -1 \; se \; (x_j - x_i) < 0 \end{cases} \qquad (2)$$

Quando existe um número alto de observações (n), a distribuição de probabilidade S tende para uma distribuição normal, com média zero e variância dada por:

$$\mathrm{Var(S)} = \frac{\mathrm{n(n-1)(2n+5)}}{18} \qquad (3)$$

O valor da estatística Z é dado pela Equação 5

$$Z = \begin{cases} \frac{S-1}{\sqrt{Var\,(S)}} & S > 0 \\ 0 & S = 0 \\ \frac{S-1}{\sqrt{Var\,(S)}} & S < 0 \end{cases} \qquad (4)$$

Valores positivos de Z indicam tendências crescentes, enquanto valores negativos de Z denotam tendências decrescentes. As tendências de teste são realizadas ao nível de significância específico. Neste trabalho será utilizado nível de significância de 5%.

2.2 Sen's slope.

A magnitude de tendência em diversas séries históricas foi o foco de inúmeras investigações ao longo da última década (Adarsh e Reddy, 2015; Deka et al., 2016; Huang et al., 2024). Quando uma série histórica exibe uma tendência linear, sua inclinação pode ser estimada por meio da regressão linear. Contudo, essa estimativa só é considerada válida na ausência de correlação serial e é altamente sensível a outliers.

Para superar essas limitações, Yue e Pilon (2004), desenvolveu um método mais robusto, o Sen's Slope (*b*), que é calculado da seguinte forma:

$$\mathrm{Q_i} = \frac{\mathrm{P_j - P_k}}{\mathrm{j-k}} \text{ para j>k} \qquad (5)$$

onde Q_i representa a inclinação individual de cada par de pontos, P_i e P_k são os dados da série histórica nos tempos *j* e *k*, respectivamente, e *j* > *k*. Se n for um número total de pontos de dados, o número total de estimativas de inclinação calculada é $N = \frac{n(n-1)}{2}$.

O coeficiente *b* é determinado como mediana dessas *N* estimativas de inclinação:

$$\mathrm{b = Mediana(Q_i)} \qquad (6)$$

Se o número de estimativas de inclinação (N) for ímpar, a estimativa de inclinação *b* é o valor central ordenado. Se N for par, *b* é a média dos dois valores centrais ordenados, a robustez deste método é amplamente descrita por (Yue e Pilon, 2004).

2.3 Modelo SARIMA

O modelo SARIMA é uma extensão do modelo ARIMA proposto por Box et al.(2015), que inclui componentes sazonais. Ele é indicado para séries temporais que apresentam padrões sazonais recorrentes. O modelo SARIMA é denotado por SARIMA(p,d,q)(P,D,Q)$_m$. Onde o *p* é a ordem do termo autorregressivo (AR), d é o número de diferenciações não sazonais necessárias para tornar a série estacionária; *q* é a ordem do termo de médias móveis (MA); *P* é a ordem do termo autorregressivo sazonal; *D* é o número de diferenciações sazonais; *Q* é a ordem do termo de médias móveis sazonais; por fim, *m* é o período sazonal da série.

A equação geral do modelo SARIMA pode ser escrita como:

$$\phi_p(B^m)\phi_p(B)(1-B)^d(1-B^m)^D Y_t = \Theta_0(B^m)\Theta_a(B)\varepsilon_t \qquad (7)$$

B é operador de defasagem, definido como $B^k Y_t = Y_{t-k}$; $\phi_p(B) = 1 - \phi_1 B^1 - \phi_2 B^2 - \cdots - \phi_p B^P$ é o polinômio autorregressivo de ordem *p*; $\theta_q(B) = 1 + \theta_1 B \quad + \theta_2 B^2 + \cdots + \theta_q B^q$ é o polinômio de médias móveis de ordem *q*; $\Phi_p(B^m) = 1 - \Phi_1 B^m - \Phi_2 B^{2m} - \cdots - \Phi_p B^{Pm}$ é o polinômio autorregressivo sazonal de ordem *P*; $\Theta_Q(B^m) = 1 + \Theta_1 B^m + \Theta_2 B^{2m} + \cdots + \Theta_Q B^{Qm}$ é o polinômio de médias móveis sazonais de ordem *Q*; $(1-B)^d$ é o operador de diferenciação não sazonal de ordem d; $(1-B^m)^D$ é o operador de diferenciação sazonal de ordem *D*; Y_t é o valor da série temporal no tempo *t* e ε_t é um termo de erro aleatório no tempo *t*, assumido como ruído branco.

2.4 Seleção do modelo

A maioria dos estudos emprega a função de autocorrelação parcial (PACF) e a função de autocorrelação (ACF) para identificar o modelo mais adequado (Mirzavand e Ghazavi, 2015). No entanto, visando aprimorar a precisão na seleção do modelo, a presente pesquisa adotou, além da PACF e da ACF, os critérios de informação de Akaike (AIC) e o Bayseiano (BIC) (Dabral e Murry, 2017). A formulação matemática para o AIC é definida como:

$$\mathrm{AIC} = -2\log \mathrm{L} + 2\mathrm{M} \qquad (8)$$

em que, m = (p + q + P + Q) é o número de termos estimados no modelo e *L* denota a função de verossimilhança dos modelos ARIMA e é uma função monotonicamente decrescente da soma dos resíduos ao quadrado. A formulação matemática do BIC é definida como:

$$\mathrm{BIC} = -2\log \mathrm{L} + \mathrm{mln(n)} \qquad (9)$$

Uma das maneiras de validar a precisão dos modelos de previsão propostos é por meio da análise estatística de erros. As métricas mais comuns para avaliar o quão bem as previsões do modelo (P_i) correspondem aos valores reais observados (O_i) incluem: O *MAE* mede a média das magnitudes dos erros em um conjunto de previsões, sem considerar sua direção. Por ser calculado em unidades absolutas, ele é fácil de interpretar.

$$\mathrm{MAE} = \frac{1}{\mathrm{n}}\sum_{i=1}^{n} |\mathrm{P_i} - \mathrm{O_i}| \qquad (10)$$

O coeficiente de correlação de Pearson (r) varia de -1 a 1 sendo mais próximo de 1, maior é a tendência linear de existir uma dependência linear entre as variáveis (Oliveira 2019).

$$r = \frac{cov(P_o,P_t)}{\sqrt{var\,(P_o)Var(P_t)}} = \frac{\sum(P_o-\overline{P_o})*(P_t-\overline{P_t})}{\sqrt{\sum((P_o-\overline{P_o})^2*(P_t-\overline{P_t})^2}} \qquad (11)$$

O coeficiente de determinação (R^2) é uma métrica estatística entre 0 e 1 que indica a proporção da variância na variável dependente que é explicada pelas variáveis independentes no seu modelo de regressão, mostrando o quão bem o modelo se ajusta aos dados; um R^2 próximo de 1 significa um ajuste perfeito.

$$R^2 = \frac{\sum(P_o-\overline{P_o})*(P_t-\overline{P_t})}{\sqrt{\sum((P_o-\overline{P_o})^2*(P_t-\overline{P_t})^2}} \qquad (12)$$

O coeficiente de eficiência de Nash-Sutcliffe (NS) é frequentemente utilizado para quantificar a qualidade da série temporal ajustada (Nash e Sutcliffe, 1970). Esse coeficiente pode variar entre - ∞ a 1, sendo o valor 1 indicativo de um perfeito ajuste. Conforme (Camelo et al., 2018), quando o valor do NS resultar maior que 0,75 o desempenho do modelo é considerado bom. Para valores de NS entre 0,36 e 0,75 o desempenho é considerado aceitável, enquanto valores de NS inferiores a 0,36 fazem com que o modelo seja julgado como inaceitável. O coeficiente NS é dado por:

$$\mathrm{NS} = 1 - \frac{\sum_{i=1}^{n} (O_i - P_i)^2}{\sum_{i=1}^{n} (O_i - \overline{O})^2} \qquad (13)$$

onde: O_i é o valor observado no tempo *i*; P_i é o valor simulado/previsto no tempo *i*; $\bar{O}$ é a média dos valores observados e *n* é o número de observações.

O Percent bias (*Pbias*) avalia a tendência que a média dos valores simulados tem em relação aos observados. O valor ideal do Pbias é zero, valores positivos indicam uma subestimação do modelo, e valores negativos de superestimação.

$$P_{bias} = \left[\frac{\sum(O_i - P_i}{\sum O_i}\right] \qquad (14)$$

2.5 Índice de Anomalia de Chuva (IAC) e índices oceânicos.

Na etapa de análise do grau de severidade e duração dos períodos secos e úmidos utilizou-se o cálculo do IAC proposto por Van Rooy (1965). Obteve-se o IAC da área experimental do INSA por meio das Equações 14 e 15: onde N precipitação anual, $\underline{N}$ precipitação média anual da série histórica, $\overline{M}$ média das dez maiores precipitações mensais da série histórica, $\overline{X}$ média das dez menores precipitações mensais da série histórica.

$$\mathrm{IAC} = 3 * \left[\frac{(N - \overline{N})}{(\overline{M} - \overline{N})}\right] \text{ para anomalias positivas,} \qquad (15)$$

$$\mathrm{IAC} = -3 * \left[\frac{(N - \overline{N})}{(\overline{X} - \overline{N})}\right] \text{ para anomalias negativas,} \qquad (16)$$

Tabela 1- Classificação da pluviosidade segundo o Índice de Anomalia de Chuva para a área experimental do INSA).

IAC	Classe de Intensidade
>4	Extremamente chuvoso
2 a 4	Muito chuvoso
0 a 2	Chuvoso
0 a -2	Seco
-2 a -4	Muito seco
Abaixo de -4	Extremamente Seco

Fonte: Van Rooy (1965).

Para investigar a relação entre os padrões climáticos globais e o regime de seca regional, empregou-se a análise de Correlação de Pearson entre o Índice de Anomalia de Chuva (IAC ou RAI - *Rainfall Anomaly Index*). O IAC foi correlacionado com o Índice Oceânico Niño (ONI) e as anomalias de Temperatura da Superfície do Mar (TSM) nas quatro principais regiões de monitoramento do ENOS (Niño 1+2, Niño 3, Niño 4 e Niño 3.4).

Estes índices são cruciais, pois as variações de TSM no Pacífico Tropical são o principal mecanismo modulador da precipitação no Nordeste do Brasil. Os dados do ONI e das regiões Niño foram obtidos no National Centers for Environmental Information (NCEI) da NOAA (disponível em: https://www.ncei.noaa.gov/access/monitoring/enso/).

Adicionalmente, incluiu-se o Índice de Dipolo do Atlântico Sul (SAODI), que mede o gradiente de TSM entre os Oceanos Atlânticos Tropical Norte e Sul, um fator que influencia diretamente a posição da Zona de Convergência Intertropical (ZCIT) e, consequentemente, as chuvas na região (Cavalcanti et al., 2020; Santos et al., 2021). Os dados do SAODI foram acessados através da plataforma de monitoramento da UNIFEI (disponível em: https://meteorologia.unifei.edu.br/teleconexoes/indice?id=saodi).

Para avaliar a influência remota das anomalias da TSM sobre a pluviometria local, foi realizada uma análise de correlação cruzada entre as séries mensais dos índices climáticos e o IAC. Foram aplicadas defasagens temporais (lags) variando de -6 a +6 meses. A adoção desse intervalo justifica-se para identificar a memória do sistema climático: defasagens negativas indicam que a alteração no oceano precede a anomalia de chuva, servindo como sinal precursor (potencial preditivo), enquanto as defasagens positivas permitem avaliar a

persistência da correlação e o tempo de decaimento da influência oceânica após o evento chuvoso.

3. RESULTADOS E DISCUSSÃO

3.1 Análise descritiva

A análise estatística descritiva mensal da precipitação (2011–2025) reflete o regime de extrema variabilidade característico do semiárido brasileiro, onde a irregularidade temporal e espacial das chuvas é um fator determinante para a disponibilidade hídrica e o planejamento agrícola (Moura, 2014)

Os resultados confirmam (Tabela 2) o padrão de concentração de chuvas em um curto período do ano. Os meses de maio e julho destacam-se como o núcleo do período chuvoso, 114.99 e 99.5 mm, respectivamente, consistente com o regime que se estende de janeiro a maio na maior parte do Semiárido (Júnior e Lucena, 2021). Em contrapartida, a precipitação média é drasticamente reduzida nos meses de outubro (6.03 mm) e novembro (11.35 mm), caracterizando o período seco com fortes déficits hídricos (Alves, 2011).

Tabela 2- Estatísticas Descritivas Mensais da Precipitação (mm) no Período de 2011 a 2025.

Mês	min	max	Média	Desvio-padrão	CV	Curtose	Assimetria
Janeiro	0,0	131,2	32,4	36,56	1,13	3,2	1,70
Fevereiro	0,0	115,6	37,01	37,05	1,00	-0,22	0,98
Março	10,6	253,2	92,66	84,05	0,91	-1,05	0,70
Abril	0,0	253,2	83,4	66,12	0,79	2,28	1,36
Maio	26,2	358,0	114,99	97,97	0,85	2,00	1,59
Junho	12,9	277,0	94,57	69,67	0,74	2,69	1,53
Julho	6,9	211,6	99,5	57,63	0,58	0,49	0,59
Agosto	0,7	88,0	32,96	30,71	0,93	-1,12	0,64
Setembro	0,0	48,6	15,74	15,58	0,99	0,91	1,37
Outubro	0,0	30,9	6,03	7,84	1,30	8,74	2,71
Novembro	0,0	58,0	11,35	19,68	1,73	2,07	1,79
Dezembro	0,0	99,4	30,7	35,43	1,15	-032	1,00

Fonte: Elaborado pelos autores (2025).

O Coeficiente de Variação (CV) elevado nos meses de novembro (1,73), outubro (1,30) e janeiro (1,13), espelha a alta imprevisibilidade da precipitação na região. Valores de CV próximos ou superiores a 1 indicam que o desvio-padrão é tão grande quanto a média, ou seja, a precipitação anual pode variar drasticamente de um ano para o outro (Marengo, 2007). Essa variabilidade interanual acentuada é uma das principais causas de anos de seca severa e está fortemente associada à influência de fenômenos de grande escala, como o ENSO (*El Niño–Southern Oscillation*) e as variações de Temperatura da Superfície do Mar (TSM) no Oceano Atlântico Tropical (Santos et al., 2010; Cavalcanti et al., 2015).

A série diária de precipitação apresentada na Figura 2A revela a natureza altamente intermitente e irregular do regime pluviométrico no Semiárido brasileiro, com longos períodos secos intercalados por eventos intensos concentrados em poucos dias. Essa distribuição temporária, marcada por episódios extremos de curta duração, é típica de ambientes dominados pela convecção profunda e modulados por sistemas meteorológicos de mesoescala, como Vórtices Ciclônicos de Altos Níveis e Distúrbios Ondulatórios de Leste (Kousky, 1979; Souza e Ambrizzi, 2006). A variação interanual observada, com anos de maior acumulação associados a episódios frequentes de eventos convectivos e anos secos dominados por forte subsidência, reflete a influência combinada dos modos de variabilidade oceânica, em especial a Oscilação Interdecadal do Pacífico e o estado térmico do Atlântico Tropical (Rodrigues et al., 2022).

Figura 2 - Variabilidade temporal da precipitação: **A**. série diária e **B**. distribuição mensal da chuva entre 2011 e 2024.

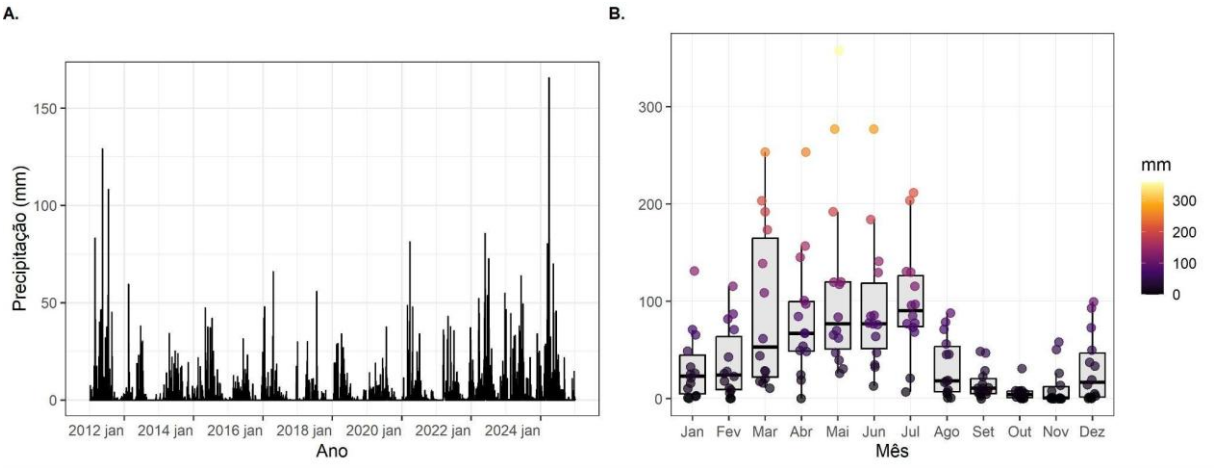

Fonte: Elaborado pelos autores (2025).

A distribuição mensal da chuva (Figura 2B) evidencia um ciclo anual bem definido, com maior concentração entre fevereiro e maio, período clássico da estação chuvosa do Nordeste Setentrional, associado a atuação da Zona de Convergência Intertropical (ZCIT) e (VCANs). A amplitude da variabilidade intramensal é particularmente elevada em março e abril, indicando meses com alta frequência de eventos moderados a extremos, enquanto os meses de agosto a novembro exibem precipitações muito baixas, restritas a valores residuais.

3.2 Análise de tendência e modelagem SARIMA

A análise da tendência temporal da precipitação mensal entre 2011 e 2024 (Figura 3A) indica um aumento estatisticamente significativo, conforme revelado pelo teste de Mann-Kendall ($\tau = 0{,}1304$; $p = 0{,}0125$) e pela estimativa de *Sen*, que aponta uma inclinação de 0,106 mm $mês^{-1}$ (equivalente a 1,27 mm ano^{-1}). Embora a magnitude absoluta dessa tendência seja modesta, ela reflete uma intensificação gradual da precipitação ao longo do período, compatível com tendências positivas observadas em outras regiões semiáridas sob influência de variabilidade climática interdecadal e de teleconexões oceânicas tropicais (Moron et al., 2018; Marengo et al., 2022).

Figura 3 - Tendência temporal da precipitação mensal **A**. e desempenho do modelo SARIMA com a transformação Box-Cox **B**. Dabral e Murry (2017).

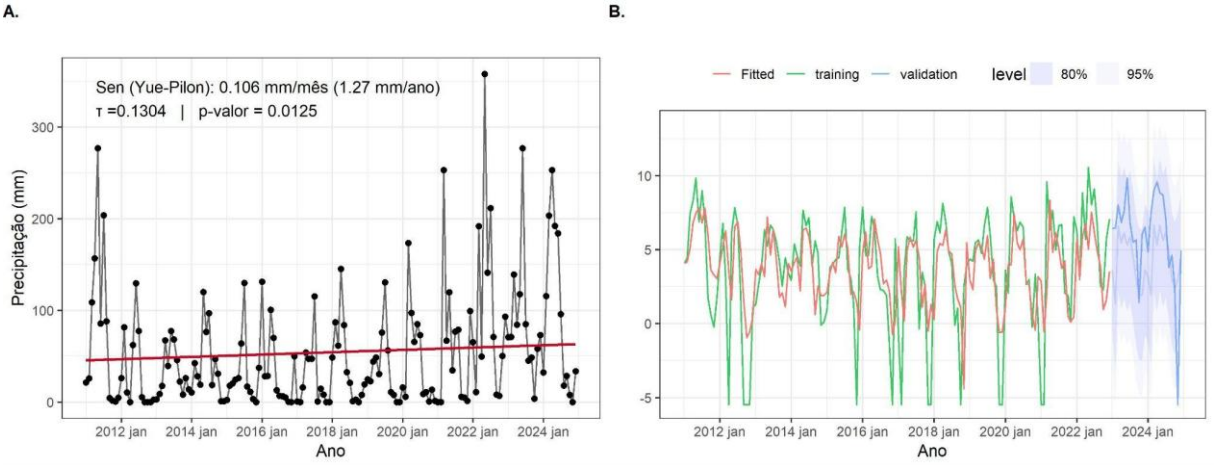

Fonte: Elaborado pelos autores (2025).

O desempenho do modelo SARIMA após aplicação da transformação Box-Cox (Figura 3B) demonstra boa capacidade de reproduzir a sazonalidade e a variabilidade de curta escala da série histórica, com ajuste coerente ao período de treinamento e manutenção da estrutura temporal no período de validação. A estabilização da variância proporcionada pela

transformação contribuiu para melhorar a qualidade do ajuste, como discutido por Dabral e Murry (2017), resultando em previsões mais realistas e com intervalos de confiança compatíveis com a incerteza inerente à precipitação em regiões semiáridas (Box et al., 2016).

A (Tabela 3) apresenta os resultados do ajuste do modelo SARIMA à série temporal de precipitação mensal. Os parâmetros de autoregressão não sazonais, ϕ_1=0.436 e ϕ_2=-0.108, indicam uma memória de curto prazo moderada na série. O coeficiente ϕ_1 positivo demonstra a inércia pluviométrica: a precipitação do mês corrente é positivamente correlacionada com a do mês imediatamente anterior, um fenômeno comum em séries climatológicas devido à persistência de padrões de circulação atmosférica (Morettin e Toloi, 2022). A necessidade de incluir a componente sazonal é evidente, dada a forte periodicidade anual da precipitação. Os parâmetros de autoregressão sazonal Φ_1=0,645 e Φ_2=0,198 refletem a dependência interanual da precipitação: o volume de chuva de um determinado mês é significativamente influenciado pelo volume do mesmo mês no ano anterior. Observa-se que os Erros Padrão (SEE) dos coeficientes sazonais (ϕ_1, ϕ_2, Θ_1) são relativamente altos, sugerindo que estas estimativas possuem maior incerteza. Este resultado pode ser atribuído à maior variabilidade nos dados anuais.

As métricas de informação (AICc = 750,5 e BIC = 770,4) fornecem um critério para a parcimônia do modelo, sendo comparativamente baixas em relação a modelos alternativos. O Teste de Ljung-Box aplicado aos resíduos do modelo resultou em χ^2= 18,03 com um valor-p de 0,801, já que, a hipótese nula de que os resíduos são ruídos branco (não correlacionados) não pode ser rejeitada (Camelo et al., 2018). Este resultado válido a adequação do modelo ao indicar que ele capturou satisfatoriamente a estrutura de dependência temporal e sazonal da série de precipitação, deixando apenas ruído aleatório nos resíduos.

Tabela 3 - Detalhes do modelo SARIMA desenvolvido na estação experimental INSA.

SARIMA $(2,1,2)(1,1,2)_{12}$	Parâmetro	ϕ_1	ϕ_2	θ_1	Φ_1	Φ_2	Θ_1
	Estimado	0,436	-0,108	-1,000	0,645	0,198	-0,543
	SEE	0,088	0,085	0,026	0,440	0,213	0,484
	AIC_C	750,5					
	BIC	770,4					
	Teste Ljung- Box	18,03					
	χ^2 *(24) valor p*	0,801					

Fonte: Elaborado pelos autores (2025).

Tabela 4 - Estatística comparativa dos valores estimados e observados de precipitação pelo Modelo SARIMA.

Mês	Estimado	Observado	Limite Inferior	Limite superior
Janeiro	19,16	32,40	-84,43	122,74
Fevereiro	26,11	37,01	-77,47	129,69
Março	60,86	92,66	-42,72	164,44
Abril	57,26	83,40	-46,33	160,84
Maio	124,00	114,99	20,42	227,59
Junho	81,91	94,54	-21,67	185,49
Julho	117,08	99,5	13,49	220,66
Agosto	26,27	32,96	-77,31	129,86
Setembro	8,66	15,74	-94,92	112,24
Outubro	3,30	6,03	-100,28	106,88
Novembro	0,78	11,35	-102,80	104,36
Dezembro	13,940	30,71	-89,64	117,52
MAE = 30,3 mm				
r = 0,66				
R^2 = 0,43				
C_{NS} =0,36				
PBIAS = -17,2%				

Fonte: Elaborado pelos autores (2025).

3.3 Índice de seca e oceânicos-atmosféricos

A Figura 4 apresenta a evolução do Índice de Anomalia de Chuva (IAC) entre 2011 e 2024, permitindo identificar a frequência e intensidade dos desvios pluviométricos ao longo do período. Observa-se predominância de valores negativos entre 2012 e 2017, indicando condições secas extremas, coerentes com a longa sequência de estiagens registradas no Nordeste durante forte persistência de El Niño e aquecimento do Atlântico Norte (Marengo et al., 2017). Esse padrão reflete a atuação combinada do ENOS e do dipolo do Atlântico na modulação da Zona de Convergência Intertropical, principal sistema indutor de chuva na região.

Figura 4 - **A.** Série temporal do Índice de Anomalia de Chuva (IAC) entre 2011 e 2024. **B.** Correlações defasadas entre o IAC sazonal e índices oceânicos-atmosféricos (ENOS e Atlântico).

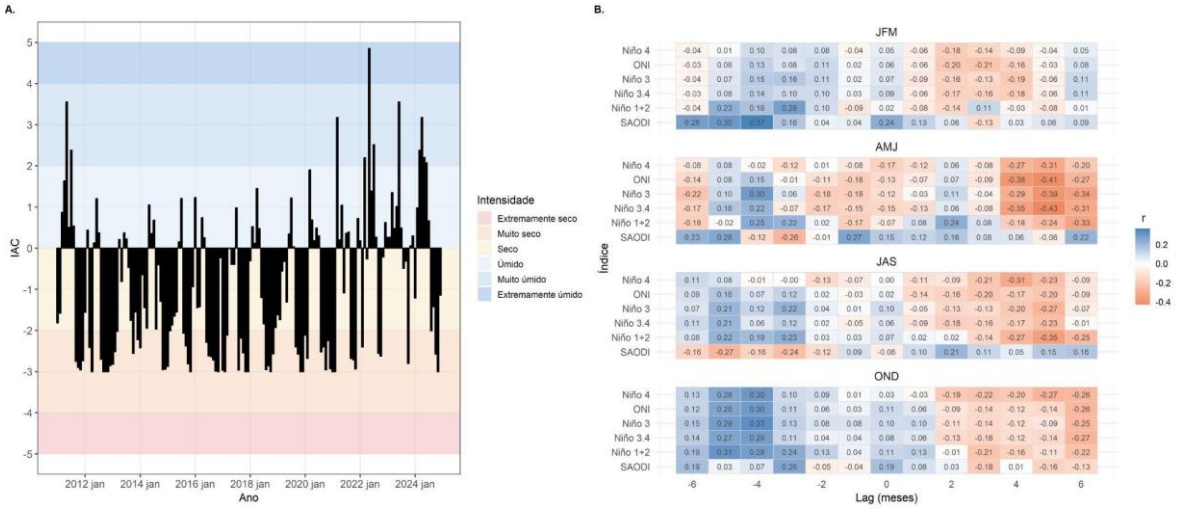

Fonte: Elaborado pelos autores (2025).

Nota-se que, após 2021, o IAC passa a exibir uma maior variabilidade, caracterizada pela alternância abrupta entre eventos muito úmidos e secos. Os episódios positivos mais intensos da série histórica destacam-se neste período recente, com picos expressivos ocorrendo principalmente em 2022 e 2023. Embora não se apresente a série temporal dos índices oceânicos, as análises de correlação (Figura 4B) corroboram o conhecimento estabelecido na literatura de que a variabilidade pluviométrica local responde fortemente às anomalias de temperatura do Pacífico (ENOS) e do Atlântico. Tais modulações oceânicas afetam diretamente o posicionamento da ZCIT e, consequentemente, os volumes de precipitação (Kayano e Capistrano, 2014; Cai et al., 2020). Ainda assim, anos recentes exibem valores negativos expressivos intercalados aos picos úmidos, sugerindo a forte influência de variabilidades de alta frequência e de efeitos locais de seca atmosférica.

4. CONSIDERAÇÕES FINAIS

Este estudo destacou a elevada variabilidade da precipitação na região semiárida da Caatinga, evidenciada por meio da análise de séries temporais e indicadores climáticos como o Índice de Anomalia de Chuva (IAC). A aplicação do modelo SARIMA permitiu detectar tendências de aumento gradual na precipitação, assim como padrões sazonais e eventos extremos de seca e chuva, reforçando a complexidade do regime pluviométrico local.

Os resultados demonstram que fenômenos oceano-atmosféricos, como La Niña e alterações na temperatura do Atlântico Tropical, têm forte influência sobre a variabilidade pluviométrica, impactando diretamente os recursos hídricos e a biodiversidade da região. A maior variabilidade observada após 2018 indica a necessidade de investimentos contínuos em monitoramento e modelagem, a fim de aprimorar a previsão de eventos extremos e subsidiar estratégias de adaptação às mudanças climáticas.

Diante dos desafios apresentados, reforça-se a importância de integrar modelos estatísticos com variáveis ambientais e oceânicas para uma compreensão mais abrangente do comportamento climático na Caatinga. Essas ações são essenciais para orientar políticas públicas, promovendo o uso sustentável dos recursos naturais e contribuindo para a resiliência das comunidades locais frente às incertezas do clima futuro.

AGRADECIMENTOS

Agradecemos ao Instituto Nacional do Semiárido (INSA-MCTIC) pela concessão de bolsa através do Programa PCI/MCTI, processo 301109/2023-0, à parceria com a Universidade Federal de Campina Grande (UFCG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq – Brasil) pelo apoio financeiro, processo número 408551/2022-4.

REFERÊNCIAS

ADARSH, S.; REDDY, M. J. Trend analysis of rainfall in four meteorological subdivisions of southern India using nonparametric methods and discrete wavelet transforms. **International Journal of Climatology**, v. 35, n. 5, 2015.

AGÊNCIA EXECUTIVA DE GESTÃO DAS ÁGUAS – AESA. *AESA Website.* Disponível em: https://www.aesa.pb.gov.br/aesa-website/. Acesso em: 21 out. 2023. 2023.

ALVARES, Clayton Alcarde et al. Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ALVES, J. M. B. Caracterização climática do Semiárido brasileiro. **Revista Brasileira de Geografia Física**, v. 4, n. 2, p. 345–360. 2011.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time Series Analysis: Forecasting and Control.** 5. ed. Hoboken: Wiley, 2016.

BRITO, S. S. B.; CUNHA, A. P. M. A.; CUNNINGHAM, C. C.; ALVALÁ, R. C.; MARENGO, J. A.; CARVALHO, M. A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v. 38, n. 2, p. 517-529, 2018.

CAI, Wenju et al. ENSO response to greenhouse forcing. **El Niño southern oscillation in a changing climate**, p. 289-307, 2020.

CAMELO, H. N.; LÚCIO, P. S.; LEAL JÚNIOR, J. B. V.; CARVALHO, P. C. M. Proposta para previsão de velocidade do vento através de modelagem híbrida ARIMAX–RNA. **Revista Brasileira de Meteorologia**, v. 33, p. 115–129. 2018.

CAVALCANTI, I. F. A.; et al. Influências de fenômenos de grande escala na variabilidade climática da América do Sul. **Climanálise**, v. 30, n. 1, p. 1–12. 2015.

CAVALCANTI, I. F. A.; SILVEIRA, V. P.; FIGUEROA, S. N.; et al. Climate variability over South America: regional and large scale features simulated by the Brazilian Atmospheric Model (BAM-v0). **International Journal of Climatology**, v. 40, n. 5, p. 2845–2869. 2020.

COSTA, R. L.; GOMES, H. B.; SILVA, F. D. S.; BAPTISTA, G. M. M.; JÚNIOR, R. L. R.; HERDIES, D. L. Cenários de mudanças climáticas para a região Nordeste do Brasil por meio da técnica de Downscaling estatístico. **Revista Brasileira de Meteorologia**, v. 35, n. spe, p. 785-801, 2020.

COSTA JÚNIOR, D. D.; CUNHA, J. E. B. L.; SILVA, B. K. N.; MELO, D. M. A.; CAVALCANTI, M. L. C.; PEREZ-MARIN, A. M. Composition and horizontal structure of the shrub-tree component of a seasonally dry tropical forest – SDTF. **Revista Floresta**, v. 54, p. e-88056. 2024.

DA SILVA, L. E. F. Aplicação do teste de Mann-Kendall para detecção de tendência no Rio Cuiabá-MT. **Research, Society and Development,** v. 9, n. 9, p. e712996560-e712996560, 2020.

DABRAL, P. P.; MURRY, M. Z. Modelling and forecasting of rainfall time series using SARIMA. **Environmental Processes**, v. 4, p. 399–419. 2017.

DEKA, R. L. et al. Spatio-temporal variability of rainfall regime in the Brahmaputra valley of North East India. **Theoretical and Applied Climatology**, v. 124, n. 3, p. 793-806, 2016.

DIAS, C. A. P.; JÚNIOR, J. A. S.; CUNHA, A. C.; et al. Índice de anomalia de chuva (IAC) e sua relação com os desastres naturais no leste da Amazônia. **Revista Brasileira de Geografia Física**, v. 15, n. 5, p. 2544–2572. 2022.

DIMRI, T.; AHMAD, S.; SHARIF, M. Time series analysis of climate variables using seasonal ARIMA approach. **Journal of Earth System Science**, v. 129, p. 149. 2020.

DOS SANTOS, S. R. Q.; CUNHA, A. P. M.; RIBEIRO-NETO, G. G. Avaliação de dados de precipitação para monitoramento do padrão espaço-temporal da seca no Nordeste do Brasil. **Revista Brasileira de Climatologia**, v. 25. 2019.

EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. *Sistema brasileiro de classificação de solos.* 3. ed. EMBRAPA. 2013.

HOLENDER, B. V.; SANTOS, E. B. Análise de tendência dos eventos de precipitação intensa no sudeste do Brasil. **Revista Brasileira de Climatologia**, v. 32, p. 584-606, 2023.

HUANG, Y.; JIN, Y.; CHEN, S. The spatiotemporal dynamics of vegetation cover and its response to the Grain for Green Project in the Loess Plateau of China. **Forests**, v. 15, n. 11, p. 1949, 2024.

INMET – INSTITUTO NACIONAL DE METEOROLOGIA. *Clima INMET.* Disponível em: https://clima.inmet.gov.br/GraficosClimatologicos/DF/83377. Acesso em: 22 out. 2023. 2023.

JÚNIOR, J. B. C.; LUCENA, R. L. Análises estatísticas da precipitação e temperatura do ar em ambientes semiáridos. **ENTRE-LUGAR**, v. 12, n. 24, p. 170-191, 2021.

KAYANO, M. T.; CAPISTRANO, V. B. How the Atlantic Multidecadal Oscillation (AMO) modifies the ENSO influence on South American rainfall. **International Journal of Climatology**, v. 34, n. 1, p. 162–178. 2014.

KOUSKY, V. E. Frontal influences on Northeast Brazil. **Monthly Weather Review**, v. 107, p. 1140–1153. 1979.

MARENGO, J. A.; ALVES, L. M.; AVALA, R. C.; et al. Climatic characteristics of the 2010–2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 90, n. 2 supl. 1, p. 1973–1985. 2017.

MARENGO, J. A.; GALDÓS, M. V.; CHALLINOR, A. D.; et al. Drought in Northeast Brazil: a review of agricultural and policy adaptation options for food security. **Climate Resilience and Sustainability**, v. 1, n. 1, p. e17. 2022.

MIRZAVAND, M.; GHAZAVI, R. A stochastic modelling technique for groundwater level forecasting in an arid environment using time series methods. **Water Resources Management**, v. 29, n. 4, p. 1315–1328. 2015.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2022.

MORON, V.; OUESLATI, B.; POHL, B.; JANICOT, S. Daily weather types in February–June (1979–2016) and temperature variations in tropical North Africa. **Journal of Applied Meteorology and Climatology**, v. 57, n. 5, p. 1171–1195. 2018.

MOURA, A. C. M. Geoprocessamento na gestão e planejamento urbano. Editora Interciência. 2014.

NNAMCHI, H. C.; LI, J.; ANYADIKE, R. N. C. Does a dipole mode really exist in the South Atlantic Ocean? **Journal of Geophysical Research: Atmospheres**, v. 116, D15. 2011.

SANTOS, C. A. C.; et al. Influência do ENSO e do Atlântico Tropical na variabilidade pluviométrica do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 2, p. 227–236. 2010.

SANTOS, P. H. A. B.; DELFINO, O. A. S.; SANTOS, R. V. R.; NASCIMENTO, M. Ajuste de um modelo de séries temporais para prever a precipitação pluviométrica. **Research, Society and Development**, v. 10, n. 6, p. e41810615643. 2021.

SILVA, V. P. R. On climate variability in Northeast of Brazil. **Journal of Arid Environments**, v. 58, n. 4, p. 575-596, 2004.

SOUZA, E. B.; AMBRIZZI, T. Atmospheric circulation and rainfall anomalies associated with tropical convection. **Theoretical and Applied Climatology**, v. 84, p. 125–139. 2006.

VAN ROOY, M. P. A rainfall anomaly index independent of time and space. **Notos**, v. 1, p. 1–8. 1965.

YUE, S.; PILON, P. A comparison of the power of the t test, Mann–Kendall and bootstrap tests for trend detection. **Hydrological Sciences Journal**, v. 49, n. 1, p. 21–37. 2004.