

PREVISÃO DE TEMPERATURA COM MODELOS SARIMA: UMA ABORDAGEM POR SÉRIES TEMPORAIS**TEMPERATURE FORECASTING WITH SARIMA MODELS: A TIME SERIES APPROACH****PREDICCIÓN DE TEMPERATURA CON MODELOS SARIMA: UN ENFOQUE DE SERIES TEMPORALES** 10.56238/revgeov17n5-101**Luiza Caroline Medeiros Godoi**

Mestre em Engenharia Ambiental

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: luizagodoii@gmail.com

Lattes: <http://lattes.cnpq.br/9978013960157467>

ORCID: 0009-0006-9963-4119

Fernando César Manosso

Doutor em Geografia

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: fmanosso@utfpr.edu.br

Lattes: <http://lattes.cnpq.br/1466197036074149>

ORCID: 0000-0003-2568-7403

RESUMO

Em um país como agroexportador como o Brasil, a análise e o monitoramento climático são essenciais para o êxito das plantações. O presente estudo analisa a aplicação do modelo Seasonal Autoregressive Integrated Moving Average (SARIMA) na modelagem e previsão de séries temporais de temperatura do ar (média, mínima e máxima) no município de Francisco Beltrão, Paraná, referentes ao período de 2014 a 2024. Inicialmente, realizou-se a análise exploratória das séries, seguida de testes de estacionariedade, decomposição temporal e avaliação da estrutura de dependência por meio das funções de autocorrelação e autocorrelação parcial. Os modelos SARIMA foram ajustados conforme a metodologia de Box Jenkins, com seleção baseada no critério de informação de Akaike. A adequação dos modelos foi avaliada a partir de métricas de erro e da análise dos resíduos. Os resultados indicam forte sazonalidade anual nas séries e um resultado preditivo positivo da modelagem, sobretudo para previsões de curto e médio prazo. Contudo, observou-se limitação na representação de eventos climáticos extremos. Concluiu-se que o modelo SARIMA constitui uma ferramenta apropriada e eficiente para a análise e previsão da temperatura do ar em escala local, podendo subsidiar o planejamento agrícola e a gestão territorial em regiões climaticamente sensíveis.

Palavras-chave: Análise de Dados. Box-Jenkins. Clima.

ABSTRACT

In a country like Brazil, which is an agricultural exporter, climate analysis and monitoring are essential for the success of crops. This study analyzes the application of the Seasonal Autoregressive Integrated Moving Average (SARIMA) model in the modeling and forecasting of air temperature time series (average, minimum, and maximum) in the municipality of Francisco Beltrão, Paraná, for the period from 2014 to 2024. Initially, an exploratory analysis of the series was performed, followed by stationarity tests, temporal decomposition, and evaluation of the dependency structure using autocorrelation and partial autocorrelation functions. The SARIMA models were fitted according to the Box-Jenkins methodology, with selection based on the Akaike information criterion. The adequacy of the models was evaluated using error metrics and residual analysis. The results indicate strong annual seasonality in the series and a positive predictive result of the modeling, especially for short- and medium-term forecasts. However, a limitation was observed in the representation of extreme climatic events. It was concluded that the SARIMA model constitutes an appropriate and efficient tool for the analysis and forecasting of air temperature on a local scale, and can support agricultural planning and territorial management in climatically sensitive regions.

Keywords: Data Analysis. Box-Jenkins. Climate.

RESUMEN

En un país como Brasil, exportador agrícola, el análisis y monitoreo climático son esenciales para el éxito de los cultivos. Este estudio analiza la aplicación del modelo SARIMA (Seasonal Autoregressive Integrated Moving Average) en la modelización y pronóstico de series temporales de temperatura del aire (promedio, mínimo y máximo) en el municipio de Francisco Beltrão, Paraná, para el período 2014-2024. Inicialmente, se realizó un análisis exploratorio de las series, seguido de pruebas de estacionariedad, descomposición temporal y evaluación de la estructura de dependencia mediante funciones de autocorrelación y autocorrelación parcial. Los modelos SARIMA se ajustaron según la metodología de Box-Jenkins, con selección basada en el criterio de información de Akaike. La adecuación de los modelos se evaluó mediante métricas de error y análisis de residuos. Los resultados indican una marcada estacionalidad anual en las series y un resultado predictivo positivo de la modelización, especialmente para pronósticos a corto y mediano plazo. Sin embargo, se observó una limitación en la representación de eventos climáticos extremos. Se concluyó que el modelo SARIMA constituye una herramienta apropiada y eficiente para el análisis y la predicción de la temperatura del aire a escala local, y puede servir de apoyo para la planificación agrícola y la gestión territorial en regiones climáticamente sensibles.

Palabras clave: Análisis de Datos. Box-Jenkins. Clima.



1 INTRODUÇÃO

A análise e a previsão de variáveis climáticas assumem papel central em áreas como meteorologia, agricultura, planejamento energético e gestão de recursos naturais. Entre essas variáveis, a temperatura do ar destaca-se pela influência exercida sobre processos naturais, atividades humanas e pela caracterização de padrões climáticos regionais e globais (Baede et al., 2001). Em um país como o Brasil, onde a agricultura ocupa posição estratégica na economia (Brasil, 2026), o monitoramento climático torna-se essencial, uma vez que a variabilidade e as mudanças do clima impactam diretamente sistemas produtivos sensíveis às condições atmosféricas (Assad; Assad, 2024).

Nesse contexto, os modelos estatísticos de séries temporais são amplamente utilizados para descrever e prever o comportamento de variáveis climáticas (Bueno; Jadoski; Lima, 2020; Carvalho et al., 2021). O modelo ARIMA destaca-se pela capacidade de capturar dependências temporais após a adequação da série à estacionariedade (Box; Jenkins; Reinsel, 2008), porém apresenta limitações na representação de estruturas sazonais recorrentes, comuns em séries de temperatura (Hyndman; Athanasopoulos, 2018). O modelo SARIMA supera essa limitação ao incorporar explicitamente componentes sazonais, tornando-se mais adequado para séries que exibem padrões periódicos regulares, como ciclos anuais ou mensais (Box; Jenkins; Reinsel, 2008). Diferentes estudos demonstram sua eficácia na modelagem e previsão de séries de temperatura em diferentes contextos climáticos e escalas temporais (Dimri; Ahmad; Sharif, 2020; Dahiya et al., 2024; Gadam; Jafari, 2025).

Diante disso, este artigo tem como objetivo analisar a aplicação do modelo SARIMA na modelagem de séries temporais de temperatura a partir de dados da cidade de Francisco Beltrão, localizada na região Sudoeste do estado do Paraná, avaliando sua capacidade de capturar padrões sazonais, de modo a contribuir para a compreensão da variabilidade térmica e subsidiar previsões mais confiáveis para a tomada de decisão em áreas sensíveis às variações climáticas.

2 REFERENCIAL TEÓRICO

O clima exerce papel fundamental no desenvolvimento da produção agrícola, de modo que mesmo alterações moderadas em seus elementos podem gerar impactos significativos nas culturas. O aumento da temperatura, por exemplo, pode limitar o crescimento de espécies adaptadas a condições mais amenas, enquanto o estresse hídrico, decorrente de secas prolongadas ou do aumento da demanda evaporativa, compromete o desenvolvimento fenológico das plantas (Lima, 2016).

A compreensão do comportamento climático regional demanda a análise da dinâmica das massas de ar, cujas propriedades podem ser modificadas por interações com elementos geográficos e por sobreposições em curtos períodos (Borsato; Massoquim, 2020). Na região Sul do Brasil, destacam-se a influência periódica da Massa Tropical Continental, de características quentes e secas, associada a temperaturas elevadas, baixa umidade e períodos de estiagem. Já o ingresso da Massa Polar Antártica,



composta por ar frio e denso é responsável por quedas acentuadas de temperatura, geadas e episódios de frio intenso, especialmente no outono e inverno (Borsato; Mendonça, 2015a; 2015b). A alternância entre essas massas condiciona o ritmo climático regional, afetando a variabilidade térmica, a distribuição das chuvas e atividades humanas como a agricultura e o abastecimento hídrico.

A temperatura do ar, resultante da interação entre sistemas atmosféricos em diferentes escalas temporais, apresenta comportamento organizado, marcado por dependência temporal, periodicidade e sazonalidade, características que a qualificam como uma série temporal (Prasad, 2024). Em séries climáticas, essa dependência manifesta-se por meio de componentes como tendência, autocorrelação e sazonalidade anual, associada ao ciclo das estações. A análise de séries temporais permite decompor e modelar essas componentes, possibilitando a quantificação da variabilidade térmica ao longo do tempo, conforme a metodologia de Box e Jenkins (Box; Jenkins; Reinsel, 2008).

Nesse contexto, os modelos Autorregressivos Integrados de Médias Móveis (ARIMA) e sua extensão sazonal (SARIMA) destacam-se como ferramentas adequadas para séries de temperatura com dependência temporal e sazonalidade bem definida. A literatura evidencia a eficácia desses modelos na representação da variabilidade térmica e na previsão climática, tanto em escala regional quanto local (Ray et al., 2021; Mata, 2019; Nunes, 2025).

3 METODOLOGIA

O estudo foi desenvolvido no município de Francisco Beltrão, localizado na Mesorregião Sudoeste do Paraná, com área aproximada de 735,11 km² (IBGE, 2022). A região apresenta significativa variabilidade térmica e pluviométrica ao longo do ano. Segundo o Instituto de Desenvolvimento Rural do Paraná (IDR-PR, 2021a), as temperaturas médias anuais situam-se em torno de 26,1 °C para a máxima e 14 °C para a mínima, com verões quentes e invernos amenos a frios, sujeitos à atuação de frentes frias e massas de ar de origem polar, podendo ocorrer geadas ocasionais.

Essas condições enquadram o município no tipo climático Cfa (subtropical úmido), conforme a classificação de Köppen-Geiger (Köppen, 1936), caracterizado por verões quentes, ausência de estação seca e elevada pluviosidade anual. Tal configuração exerce influência direta sobre as atividades agrícolas, que possuem papel relevante na economia regional.

Para o desenvolvimento do estudo, utilizaram-se dados meteorológicos fornecidos pelo Instituto de Desenvolvimento Rural do Paraná (IDR-PR), provenientes da estação localizada em Francisco Beltrão, referentes às variáveis de temperatura do ar (máxima, média e mínima). O período analisado compreende de 05 de junho de 2014 a 15 de setembro de 2024, totalizando uma série temporal de 11 anos, considerada adequada para a aplicação do modelo SARIMA por permitir a identificação da sazonalidade anual e da dependência temporal da temperatura, sem comprometer a consistência dos dados.



Foram construídas três séries temporais mensais correspondentes às variáveis de temperatura máxima, média, mínima. A elaboração das séries, bem como todas as etapas metodológicas da pesquisa, foi realizada no software RStudio (R versão 4.4.1, 2024), visando facilitar a visualização e a análise dos padrões climáticos ao longo do tempo.

A estacionariedade das séries temporais foi avaliada por meio do teste de Dickey-Fuller aumentado (ADF), conforme a Equação 1, utilizando o pacote *tseries* (Trauttmann et al., 2023). No teste, o termo α representa o intercepto, o parâmetro β indica a presença de tendência determinística e o coeficiente γ testa a existência de raiz unitária, sendo as hipóteses definidas como $H_0: \gamma = 0$ (não estacionariedade) e $H_1: \gamma < 0$ (estacionariedade).

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \phi_i \Delta y_{t-1} + \epsilon_t \quad (1)$$

onde:

Δy_t = diferença da série no tempo t .

γ = coeficiente que testa a raiz unitária ($H_0: \gamma = 0$)

ϵ_t = termo de erro.

Seguido da decomposição da série temporal (Equação 2) a fim de identificar a tendência, sazonalidade e resíduos.

$$y_t = T_t + S_t + R_t \quad (2)$$

onde:

T_t = componente de tendência.

S_t = componente sazonal.

R_t = resíduo (ruídos aleatórios).

Para o tratamento dos dados, foi utilizada a metodologia de Box-Jenkins (2008) para selecionar o modelo mais adequado para o ajuste dos dados. Com a modelagem SARIMA foram determinados os ajustes, com auxílio do pacote *forecast* (Hyndman, 2023), conforme demonstrado na Equação 3.

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D y_t = \theta_q(B)\Theta_Q(B^S)\epsilon_t \quad (3)$$



onde:

B = operador de *backshift* ($By_t = y_{t-1}$).

ϕ_p, θ_q = polinômios AR(p) e MA (q).

Φ_p, Θ_q = componentes sazonais (período S).

$\epsilon_t \sim N(0, \sigma^2)$ = ruído branco.

Na etapa de identificação dos modelos, analisaram-se a Função de Autocorrelação (FAC) e a Função de Autocorrelação Parcial (FACP), conforme a metodologia de Box e Jenkins (2008), com o objetivo de identificar a estrutura de dependência temporal da série. A FAC avalia a correlação entre a série e suas defasagens sucessivas, enquanto a FACP permite identificar a ordem do componente autorregressivo ao eliminar a influência das defasagens intermediárias.

De acordo com a abordagem Box–Jenkins, o decaimento gradual da FAC é típico de processos autorregressivos, e o corte abrupto da FACP indica a ordem do termo AR; comportamento inverso é esperado para processos de médias móveis. A definição dos parâmetros (p, d, q) foi realizada por meio da função *auto.arima*, que utiliza o critério de informação de Akaike (AIC) para selecionar a combinação mais adequada entre os componentes autorregressivos e de médias móveis.

$$AIC = 2k - 2 \ln(\hat{L}) \quad (4)$$

onde:

k = número de parâmetros.

\hat{L} = máxima verossimilhança do modelo.

Para identificar a normalidade dos resíduos, foi utilizado o teste de Shapiro-Wilk (Shapiro; Wilk, 1965), com o nível de significância de 5%, como segue na Equação 5.

$$W = \frac{(\sum_{i=1}^n a_i y_{(i)})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

onde:

a_i = coeficientes tabulados.

$y_{(i)}$ = estatísticas de ordem da amostra.



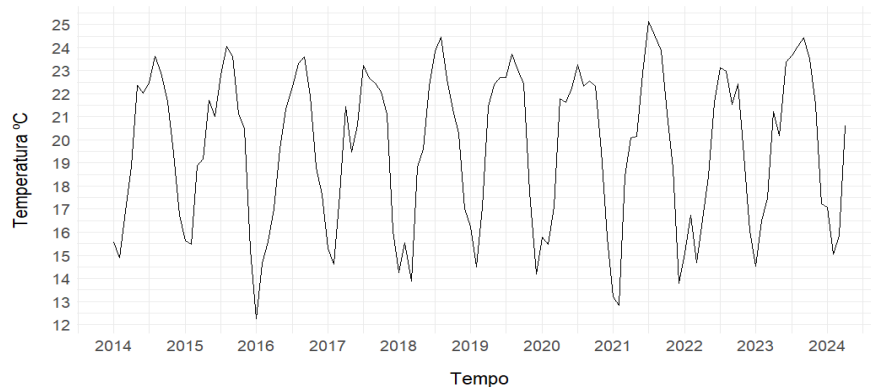
A avaliação do desempenho do modelo foi realizada por meio de métricas de erro amplamente utilizadas na análise de séries temporais. O erro médio (ME) permitiu verificar a presença de viés nas previsões, enquanto o erro absoluto médio (MAE) e o erro quadrático médio (RMSE) mensuraram a magnitude média dos desvios, sendo o RMSE mais sensível a erros extremos. O erro percentual absoluto médio (MAPE) possibilitou a avaliação relativa do desempenho do modelo, e o erro absoluto escalonado médio (MASE) permitiu a comparação com um modelo ingênuo, indicando a eficiência preditiva do modelo ajustado (Hyndman; Athanasopoulos, 2018; Makridakis; Spyridakis, 1984).

4 RESULTADOS E DISCUSSÕES

4.1 TEMPERATURA MÉDIA

A Figura 1 apresenta a série temporal das temperaturas médias mensais ao longo de onze anos, evidenciando forte sazonalidade anual, com picos no verão (dez–mar), entre 23 °C e 25 °C, e valores mínimos no inverno (jun–set), variando de 12 °C a 16 °C. Observam-se também oscilações interanuais na amplitude térmica, possivelmente associadas a eventos climáticos extremos e à variabilidade climática regional. Destaca-se o ano de 2016, marcado por um inverno rigoroso, quando junho registrou a menor temperatura em 19 anos no Paraná (G1, 2016). A amplitude térmica média anual no município foi de aproximadamente 9,5 °C, com variação interanual de $\pm 1,2$ °C, refletindo a clara alternância entre os períodos mais frios e mais quentes do ano.

Figura 1. Série temporal histórica da temperatura média mensal em Francisco Beltrão - PR entre o período de 2014 a 2024




Fonte: Dados IDR - Elaborado pela autora.

A série de temperatura média apresentou estacionariedade segundo o teste ADF (ADF = -9,2302; p-valor = 0,01), permitindo a aplicação do modelo SARIMA sem diferenciação ($d = 0$), com ordem de defasagem igual a 4 definida pelo critério AIC. A decomposição da série (Figura 2) revela a forte sazonalidade anual, típica da temperatura do ar, com invernos mais frios e verões mais quentes, o que justifica a escolha do modelo SARIMA. A tendência apresenta redução entre 2015 e 2016, seguida de recuperação e crescimento a partir de 2022.



A taxa de variação anual da tendência não foi estatisticamente significativa ($-0,020$ °C/ano; $p\text{-valor} = 0,844$), indicando que a variabilidade da série é predominantemente sazonal. Os resíduos não exibem padrão sistemático, sugerindo adequada identificação das componentes estruturais, sendo as oscilações atribuídas à variabilidade interanual e a eventos extremos.


Figura 2. Decomposição da série temporal histórica de temperatura média mensal



Fonte: Autoria própria.

A análise da Função de Autocorrelação (FAC) da série temporal (Figura 3) evidenciou um decaimento exponencial, com coeficientes significativos nos primeiros *lags* (1 e 2), seguido de rápida redução. Esse comportamento é típico de processos autorregressivos, indicando dependência temporal de curto prazo, na qual os valores atuais são influenciados por observações imediatamente anteriores. Nesse contexto, modelos autorregressivos de primeira ou segunda ordem, como AR(1) ou AR(2), mostram-se adequados para representar a estrutura temporal da série. A ausência de autocorrelações significativas em *lags* superiores a 2 reforça a condição de estacionariedade da série, corroborando os resultados do teste ADF. Assim, não se justifica a aplicação de diferenciações adicionais, que poderiam introduzir distorções na modelagem.

Figura 3. FAC da série temporal de temperatura média mensal




Fonte: Autoria própria.

A análise da Função de Autocorrelação Parcial (FACP) apresenta um corte abrupto logo após o primeiro *lag*, como podemos observar na Figura 4, confirmando a adequação de um modelo autorregressivo de ordem 1 (AR (1)). Esse padrão de decaimento exponencial observado na FAC



(Figura 3), sugere que a temperatura média no instante t depende principalmente da última observação ($t - 1$), ou seja, a observação do presente possui forte dependência da observação passada.



Fonte: Autoria própria.

O modelo SARIMA (0,0,1) (1,1,0) [12] selecionado por meio da função auto.arima (Hyndman; Khandakar, 2008), apresentou os melhores critérios de informação (AIC = 347,82). A Tabela 1 apresenta os parâmetros estimados da modelagem selecionada, onde ambos os coeficientes apresentam valores significativos. Isso indica que o modelo consegue capturar os efeitos de MA, que apontam choques aleatórios recentes que influenciam no valor capturado e na componente AR sazonal, a qual possui valor negativo. Isso sugere um padrão reverso sazonal, ou seja, temperaturas altas em um ano podem ser seguidas por valores mais baixos no mesmo mês do ano seguinte.

Tabela 1. Parâmetros do modelo SARIMA da série temporal da temperatura média mensal

Parâmetro	Coefficiente	Erro Padrão
MA (1)	0.3561	0.0959
SAR (1)	-0.5682	0.0788

Fonte: Autoria própria.

Na Tabela 2 estão presentes as métricas dos erros do modelo ajustado aos dados da temperatura média mensal. O erro médio (ME) apresenta um valor próximo de zero, o que indica neutralidade das previsões em termos de erro médio. Os valores de RMSE e MAE indicam erros de pequena magnitude relativa, evidenciando desempenho satisfatório do modelo preditivo. Destaca-se o valor do erro percentual médio (MAPE), de 5,15%, o que é um valor considerado excelente para modelos de previsões. O valor do erro absoluto escalonado médio (MASE) foi menor que 1, reforçando a qualidade do ajuste do modelo.




Tabela 2. Métricas dos erros do modelo ajustado à série temporal de temperatura média mensal

Média	Valor
ME	-0.0485
RMSE	1.2535
MAE	0.9278
MAPE	5.15%
MASE	0.6606

Fonte: Autoria própria.

A Figura 5 apresenta o periodograma dos resíduos do modelo ajustado, no qual não se observam picos significativos em frequências específicas e os valores permanecem dentro dos limites de confiança (linhas tracejadas azuis). Assim, o periodograma reforça a boa adequação do modelo, sem indícios de padrões sistemáticos não explicados.

Figura 5. Periodograma dos resíduos da modelagem da série temporal de temperatura média mensal




Fonte: Autoria própria.

Para análise da normalidade dos dados, foi selecionado o teste de Shapiro-Wilk (Shapiro; Wilk, 1965). Os resultados obtidos foram $W = 0,96779$ e o valor $p = 0,0087$, aponta que, ao nível de significância de 5%, rejeita-se a hipótese nula de que os resíduos seguem uma distribuição normal. Apesar disso, o modelo não é comprometido, pois o modelo SARIMA não exige normalidade dos resíduos para obter a previsão média.



Figura 6. Previsão da temperatura média mensal (2023-2026)



Fonte: Autoria própria.

Nos anos finais da série (2020–2025), a Figura 6 evidencia a boa capacidade preditiva do modelo SARIMA aplicado à temperatura média mensal. A comparação entre valores previstos e observados entram em acordo, com o modelo reproduzindo adequadamente as oscilações sazonais anuais da série temporal. Embora ocorram pontos onde não há adequação, a maior parte das observações permanece dentro dos intervalos de confiança de 80% e 95%, indicando que o modelo estima de forma consistente tanto a tendência central quanto a incerteza associada às previsões.


O modelo SARIMA capturou satisfatoriamente o comportamento térmico no período de teste. Ressalta-se, contudo, que essa abordagem não é a mais indicada para a previsão de eventos climáticos extremos.

4.2 TEMPERATURA MÍNIMA

A Figura 7 apresenta a série temporal das temperaturas mínimas mensais registradas em Francisco Beltrão entre 2014 e 2024, evidenciando forte sazonalidade, com picos no verão (dezembro a março) e valores mínimos no inverno (junho a setembro). A amplitude térmica da série é de aproximadamente 14 °C, com temperaturas mínimas variando entre 5 °C e 8 °C no inverno e entre 15 °C e 18 °C no verão. Destacam-se invernos mais rigorosos, como os de 2016 e 2021, que apresentaram valores inferiores aos demais anos. Em julho de 2021, o Paraná registrou o mês mais frio dos últimos 21 anos em decorrência do avanço de três massas polares (IDR-PR, 2021b). Em consonância com esse evento, Francisco Beltrão apresentou desvio negativo de $-3,2$ °C na temperatura mínima média mensal, figurando entre os dez municípios com maiores anomalias negativas do estado (IDR-PR, 2021b).



Figura 7. Série temporal histórica da temperatura mínima mensal em Francisco Beltrão - PR entre o período de 2014 a 2024




Fonte: Autoria própria.

A estacionariedade da série foi confirmada por meio do teste de Dickey-Fuller (Dickey; Fuller, 1979), cujo resultado ($ADF = -9,9667$; $p\text{-valor} = 0,01$) levou à rejeição da hipótese nula de não estacionariedade. Assim, a série mostrou-se adequada à aplicação da modelagem SARIMA, sem necessidade de diferenciação, conforme indicado por Hyndman e Athanasopoulos (2018).

A análise da decomposição da série temporal, apresentada na Figura 8, evidencia forte sazonalidade anual na temperatura mínima mensal, refletida pela curva senoidal associada à alternância das estações do ano. A componente de tendência apresenta comportamento relativamente estável ao longo da década, com leve aumento entre 2014 e 2015, seguido de queda até 2016. Essas oscilações podem estar relacionadas à atuação de fenômenos climáticos globais, como a La Niña, presente entre 2020 e 2022 (Junior; Casola, 2024), período que coincide com a tendência observada.

A taxa de variação da tendência não foi estatisticamente significativa ($-0,066$ °C por ano; $p\text{-valor} = 0,5496$), indicando que as variações observadas são predominantemente aleatórias. Os resíduos apresentam oscilações irregulares e sem padrão sistemático, o que confirma a adequada decomposição da série e reforça a confiabilidade da modelagem aplicada.


Figura 8. Decomposição da série temporal histórica da temperatura mínima mensal



Fonte: Autoria própria.




A Figura 9 apresenta a Função de Autocorrelação (FAC) da temperatura mínima mensal, evidenciando forte autocorrelação positiva no primeiro *lag* e rápido decaimento até valores próximos de zero a partir do *lag* 4, indicando dependência temporal de curta duração. A alternância entre valores positivos e negativos sugere a presença de componente autorregressivo, compatível com a modelagem SARIMA. A definição dos parâmetros autorregressivos (AR) e de médias móveis (MA) baseou-se na análise conjunta da FAC e da Função de Autocorrelação Parcial (FACP), apresentadas nas Figuras 8 e 9, priorizando os *lags* mais relevantes, conforme recomendado para séries sazonais (Hyndman; Athanasopoulos, 2018). Os resultados indicam comportamento compatível com modelos AR(1) ou ARMA(1,1), cuja especificação final foi refinada pelos critérios de informação.



Fonte: Autoria própria.

A análise da FACP (Figura 10), apresenta um rápido decaimento em direção abrupto após o primeiro *lag*, com valor significativo de $\phi_1 = -0,8$, valor que ultrapassa os limites de confiança (representado pelas linhas tracejadas azuis). Um padrão característico em um processo autorregressivo de ordem 1 (AR (1)) (Box; Jenkins; Reinsel, 2008). Em seguida, os próximos lags apresentam valor próximo a zero, indicando a adequação da modelagem nessa série temporal, porém para validação do modelo foi utilizado os critérios de informação.



Fonte: Autoria própria.

O modelo SARIMA selecionado foi o (0,0,1)(2,1,0)[12], estimado por meio da função *auto.arima* (Hyndman; Khandakar, 2008), apresentando o menor valor de AIC (378,63). O resultado indica ausência de tendência não sazonal, presença de dependência de curto prazo associada a choques



aleatórios e forte estrutura sazonal anual, representada pelos componentes autorregressivos sazonais e pela diferenciação sazonal.

Os coeficientes estimados (Tabela 4) mostraram-se estatisticamente significativos, destacando-se a componente sazonal SAR(1) e o termo MA(1), confirmando a sazonalidade marcada da série e a dependência de curto prazo. A componente sazonal negativa indica alternância entre ciclos sazonais, enquanto o termo MA(1) aponta influência dos erros recentes sobre a série.

Tabela 4. Coeficientes do modelo SARIMA da série temporal mínima mensal

Parâmetro	Coefficiente	Erro Padrão
MA (1)	0.3214	0.1029
SAR (1)	-0.5547	0.1054
SAR (2)	-0.1917	0.1134

Fonte: A autoria própria.

O modelo SARIMA apresentou desempenho satisfatório, conforme indicado pelas métricas de erro (Tabela 5). Os valores de RMSE e MAE apontam desvios médios aceitáveis entre previsões e observações, enquanto o MAPE de 9,61% indica precisão superior a 90%. O MASE inferior a 1 reforça a adequação do modelo. Contudo, o valor do RMSE (1,456) sugere limitações para aplicações que exigem maior precisão, indicando a necessidade de refinamentos para aprimorar o desempenho preditivo.

Tabela 5. Métricas dos erros do modelo ajustado à série temporal de temperatura mínima mensal


Média	Valor
ME	-0.108
RMSE	1.456
MAE	1.084
MAPE	9.61%
MASE	0.739

Fonte: A autoria própria.

A Figura 11 apresenta o periodograma dos resíduos da temperatura mínima mensal, os quais permanecem dentro dos limites de confiança, indicando adequada especificação do modelo. O teste de Shapiro-Wilk (p-valor = 0,04052) rejeitou a hipótese de normalidade ao nível de 5%; contudo, essa condição não compromete a validade da modelagem, uma vez que o modelo SARIMA não exige resíduos normalmente distribuídos.



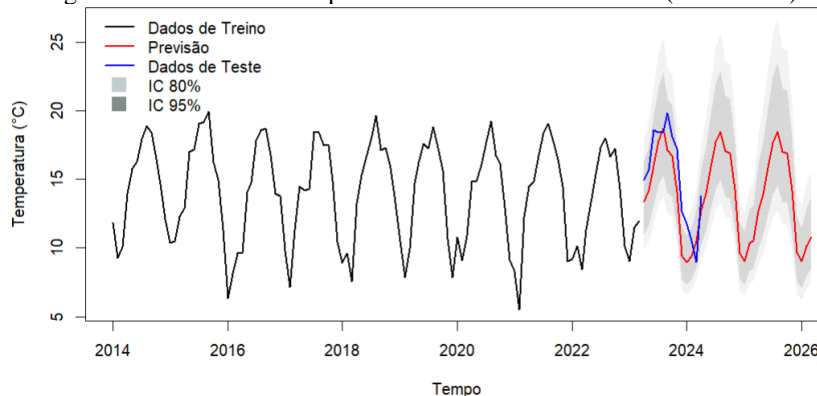
Figura 11. Periodograma dos resíduos da modelagem da série temporal mínima mensal



Fonte: Autoria própria.

A Figura 12 apresenta as previsões da temperatura mínima mensal obtidas pelo modelo SARIMA, evidenciando a forte sazonalidade anual da série. O modelo reproduz adequadamente o padrão cíclico observado nos dados, com boa aderência entre valores previstos e observados, apesar de discrepâncias pontuais, sobretudo em extremos locais. Observa-se ainda a ampliação dos intervalos de confiança de 80% e 95% com o aumento do horizonte de previsão, refletindo a maior incerteza preditiva. De modo geral, o modelo mostrou-se adequado para previsões de curto a médio prazo, embora apresente limitações na captura de eventos climáticos extremos.

Figura 12. Previsão da temperatura mínima média mensal (2023-2026)



Fonte: Autoria própria.


4.3 TEMPERATURA MÁXIMA

A Figura 13 apresenta a série temporal da temperatura máxima mensal no período de estudo, evidenciando forte sazonalidade, com picos no verão (dez–mar), em torno de 30 °C, e valores mínimos no inverno (jun–ago), próximos de 19 °C, resultando em amplitude térmica de aproximadamente 13 °C, característica do clima subtropical úmido da região. Observam-se também variações interanuais, com destaque para anos de extremos térmicos mais pronunciados. O ano de 2021 apresentou as maiores médias de temperatura máxima, superiores a 32,5 °C, possivelmente associadas à atuação do fenômeno La Niña, enquanto 2017 registrou os menores valores médios, abaixo de 30 °C. Os anos de 2018 e 2023 também se destacam por médias elevadas. O contraste observado entre 2021 e 2022 evidencia a alta variabilidade térmica da série.



A influência da La Niña entre 2021 e 2022 contribuiu para períodos de estiagem e aumento da temperatura máxima no Sul do Brasil, em função da menor cobertura de nuvens e maior incidência solar (Fantin; Walzburiech, 2025). Adicionalmente, mudanças no uso e cobertura do solo, como o aumento de áreas com solo exposto, têm sido associadas à intensificação das temperaturas do ar, conforme apontado por um estudo realizados no Paraná (Borrozzino et al., 2013).


Figura 13. Série temporal histórica da temperatura máxima média mensal em Francisco Beltrão - PR entre o período de 2014 a 2024



Fonte: Autoria própria.

A estacionariedade da série foi confirmada pelo teste de Dickey-Fuller ($ADF = -7,7371$; $p\text{-valor} = 0,01$), permitindo a aplicação do modelo SARIMA. A decomposição da série (Figura 14) aponta forte sazonalidade anual, típica do clima subtropical úmido da região, reforçando a adequação da modelagem. A tendência apresenta comportamento não linear, com leve declínio em 2015, crescimento entre 2016 e 2021 e queda em 2022, em consonância com os menores valores de temperatura máxima observados nesse ano. Nos anos mais recentes (2023–2024), observa-se nova elevação das temperaturas, compatível com o aumento de períodos mais quentes no Paraná (Paraná, 2023). A taxa de variação anual não é estatisticamente significativa ($0,034\text{ }^\circ\text{C}$; $p\text{-valor} = 0,7453$), indicando predomínio de oscilações sazonais. Os resíduos exibem comportamento aleatório, confirmando a adequação da decomposição da série.

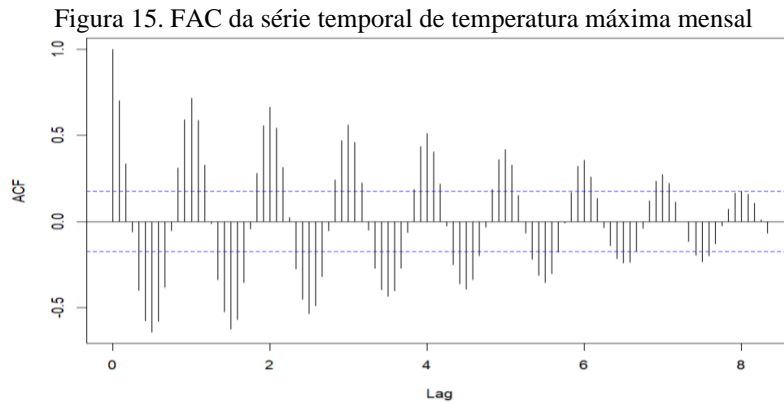
Figura 14. Decomposição da série temporal histórica da temperatura máxima mensal




Fonte: Autoria própria.



A Figura 15 apresenta a FAC da série temporal de temperatura máxima mensal, com autocorrelação significativa em diversos lags, o que sugere a dependência temporal persistente, típico em séries não estacionárias e sazonais. O decaimento das lags é lento e pode indicar que a série precise de diferenciação. Os *lags* finais apresentam baixa correlação, devido à proximidade de zero, nesses casos não há uma dependência temporal marcante.



A Figura 16 ilustra a FACP da série temporal, com um pico significativo no primeiro *lag* ($\phi_1 = -0,6$), seguido de valores dentro das linhas de confiança. Dessa forma, o corte abrupto entre o primeiro e o segundo *lag*, sugere a adequação do componente autorregressivo de ordem 1 (AR (1)). Entretanto, para a seleção da adequação da modelagem SARIMA foi utilizada a função `auto.arima` (Hyndman; Khandakar, 2008), conforme o melhor critério de informação.



Por meio da função `auto.arima` (Hyndman; Khandakar, 2008) foi selecionado a ordem (0,0,1) (1,1,1) [12] da modelagem SARIMA, com o valor de $AIC = 394,99$. A Tabela 6 dispõe dos coeficientes de cada parâmetro pertencente a ordem, juntamente com as métricas de erro padrão deles, a fim de observar a adequação do modelo escolhido. O coeficiente MA (1) é significativo estatisticamente e apresenta valor positivo, indicando a presença do ruído branco e com dependência a curto prazo. Entretanto, os demais coeficientes sugerem uma adequação moderada do modelo, devido aos valores elevados do erro padrão.



Tabela 6. Coeficientes do modelo SARIMA da série temporal máxima mensal

Parâmetro	Coefficiente	Erro Padrão
MA (1)	0.2313	0.0951
SAR (1)	-0.0817	-0.1622
SMA (1)	-0,8007	0.2244

Fonte: Autoria própria.

Conforme indicado pela análise da FAC, foi necessária a aplicação de diferenciação para aprimorar a modelagem. A presença de tendência e sazonalidade foi avaliada por meio das funções *ndiffs()* e *nsdiffs()* do pacote *forecast* (Hyndman; Khandakar, 2008), que indicaram a necessidade de uma diferenciação sazonal de ordem 1 (*nsdiffs* = 1). Observou-se ainda possível variância crescente ao longo do tempo, característica comum em séries meteorológicas, o que motivou a aplicação de uma transformação logarítmica natural à série.

Após os ajustes, o modelo selecionado pela função *auto.arima* foi o SARIMA (1,0,0)(1,1,1)[12], apresentando o menor valor de AIC (-247,43). Os coeficientes estimados (Tabela 7) indicam a presença de dependência autorregressiva de curto prazo (AR(1)) e forte componente sazonal capturada pela média móvel sazonal (SMA(1)), enquanto o termo SAR(1) não se mostrou estatisticamente significativo. O menor valor de AIC confirma a melhora do ajuste em relação à série original, evidenciando a estabilização da variância e o melhor desempenho da modelagem SARIMA.

Tabela 7. Coeficientes do modelo SARIMA da série temporal máxima mensal após transformação logarítmica

Parâmetro	Coefficiente	Erro Padrão
AR (1)	0.2015	0.0993
SAR (1)	-0.1424	-0.1501
SMA (1)	-0,8144	0.2271

Fonte: Autoria própria.

A adequação do modelo ajustado é confirmada pelas métricas de erro apresentadas na Tabela 8. O valor de ME próximo de zero indica ausência de viés sistemático, enquanto os baixos valores de RMSE e MAE revelam bom controle dos resíduos. O MAPE reduzido aponta excelente desempenho preditivo, com erro médio em torno de 1%, e o MASE inferior a 1 demonstra que o modelo supera o desempenho do modelo ingênuo. Em conjunto, essas métricas, associadas aos critérios de informação previamente discutidos, comprovam a eficiência do modelo na representação da dinâmica da temperatura máxima mensal.




Tabela 8. Métricas dos erros do modelo ajustado à série temporal de temperatura máxima mensal

Média	Valor
ME	0.0048
RMSE	0.0581
MAE	0.0442
MAPE	1.36%
MASE	0.6137

Fonte: Autoria própria.

O periodograma dos resíduos da temperatura máxima mensal (Figura 17) indica que estes se mantêm dentro dos limites de confiança, confirmando a boa adequação do modelo SARIMA. O teste de Shapiro-Wilk (p-valor = 0,00565) rejeitou a hipótese de normalidade ao nível de 5%; contudo, essa condição não compromete a validade do modelo. O valor de $W = 0,965$ sugere quase normalidade, indicando que o modelo capturou adequadamente os principais padrões da série, com desvios moderados da normalidade.

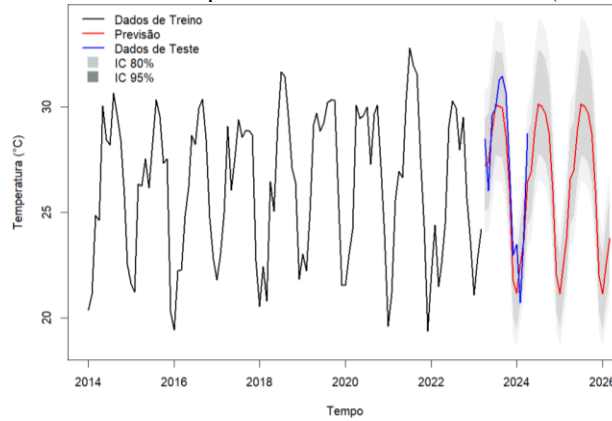
Figura 17. Periodograma dos resíduos da modelagem da série temporal máxima mensal



Fonte: Autoria própria.

A Figura 18 apresenta a previsão da temperatura máxima média mensal obtida pelo modelo SARIMA, demonstrando adequada captura da sazonalidade da série temporal. Observa-se que os dados do período de teste permanecem entre a linha de previsão e o intervalo de confiança de 95%, indicando boa aderência do modelo. Apesar disso, o desempenho tende a ser limitado em situações de picos ou eventos fora do padrão sazonal esperado, os quais não são plenamente capturados pela modelagem.

Figura 18. Previsão temperatura máxima média mensal (2023-2026)



Fonte: Autoria própria.

5 CONCLUSÃO

Este estudo demonstrou que o modelo SARIMA é uma ferramenta adequada para a modelagem e previsão de séries temporais de temperatura do ar em escala local, sendo capaz de capturar de forma eficiente a sazonalidade anual e a dependência temporal presentes nos dados de Francisco Beltrão, PR. As análises estatísticas indicaram bom desempenho dos modelos ajustados, com métricas de erro reduzidas e resíduos compatíveis com ruído branco, confirmando a qualidade do ajuste.

As previsões realizadas mostraram-se consistentes para horizontes de curto e médio prazo, embora limitem-se na representação de eventos climáticos extremos, característica esperada de modelos lineares univariados. Ainda assim, os resultados reforçam a utilidade do SARIMA como instrumento de apoio ao planejamento agrícola e à análise climática regional. Estudos futuros podem aprimorar a abordagem por meio da ampliação da série histórica e da incorporação de variáveis explicativas adicionais, visando maior precisão preditiva. Além disso, eventos climáticos extremos não são capturados pela modelagem, os quais podem impactar significativamente tanto a área urbana, como a área rural.

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), o qual foi indispensável para a realização desta pesquisa e para a continuidade da formação acadêmica.



REFERÊNCIAS

- ASSAD, E. D.; ASSAD, M. L. R. C. L. Mudanças do clima e agropecuária: impactos, mitigação e adaptação. desafios e oportunidades. **Estudos Avançados**, Online, v. 38, n. 112, p. 271-292, 2024. <https://doi.org/10.1590/s0103-4014.202438112.015>.
- BAEDE, A. P. M.; AHLONSOU, E.; DING, Y.; SCHIMEL, D. **The Climate System: an Overview**. In: INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). *Climate Change 2001: The Scientific Basis*. Cambridge: Cambridge University Press, 2001. cap. 1, p. 87–98. Disponível em: <https://www.ipcc.ch/site/assets/uploads/2018/03/TAR-01.pdf>.
- BORROZZINO, E. et al. Mudanças no uso do solo e impactos sobre a temperatura do ar e do solo no estado do Paraná, Brasil. **Enciclopédia Biosfera**, Centro Científico Conhecer – Goiânia, v. 9, n. 16, p. 1544–1553, 2013. Disponível em: <https://conhecer.org.br/enciclop/2013a/agrarias/Mudancas%20no%20uso%20do%20solo.pdf>.
- BORSATO, V. A.; MASSOQUIM, N. Os movimentos, as áreas de atuação e as propriedades das massas de ar no Brasil. **Geomae**, Campo Mourão, v. 11, n. 1, p. 27-56, 2020. Disponível em: <https://periodicos.unespar.edu.br/geomae/article/view/7690>.
- BORSATO, V. A.; MENDONÇA, F. A. A espacialização dos sistemas atmosféricos e a análise rítmica para o centro-sul do Brasil. **GEOUSP Espaço e Tempo (Online)**, São Paulo, Brasil, v. 19, n. 3, p. 585–604, 2015a. <https://doi.org/10.11606/issn.2179-0892.geousp.2015.107613>.
- BORSATO, V. A.; MENDONÇA, F. A. Participação da Massa Polar Atlântica na dinâmica dos sistemas atmosféricos no Centro Sul do Brasil. **Mercator**, Fortaleza, v. 14, n. 01, p. 113-130, 26 abr. 2015b. <http://dx.doi.org/10.4215/rm2015.1401.0008>.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4. ed. Hoboken: Wiley, 2008. 784 p.
- BRASIL. Ministério da Agricultura e Pecuária. **Produção agrícola nacional posiciona o Brasil entre os principais produtores e exportadores de alimentos do mundo**. Brasília, 20 mar. 2026. Disponível em: <<https://www.gov.br/agricultura/pt-br/assuntos/noticias/producao-agricola-nacional-posiciona-o-brasil-entre-os-principais-produtores-e-exportadores-de-alimentos-do-mundo>>.
- BUENO, J. C. M.; JADOSKI, S. O.; LIMA, V. A. Estudo de características climáticas da região de Guarapuava por meio de análise de série temporal e modelagem ARIMA. **Research, Society And Development**, Online, v. 9, n. 5, p. 1-18, 28 mar. 2020. <https://doi.org/10.33448/rsd-v9i5.3119>.
- CARLETON, T. A.; HSIANG, S. M. Social and economic impacts of climate. **Science**, Online, v. 353, n. 6304, p. 1-17, 9 set. 2016. <https://doi.org/10.1126/science.aad9837>.
- CARVALHO, R. L. S. *et al.* Comportamento das séries temporais de temperatura do ar, umidade e precipitação pluviométrica no município de Ariquemes. **Revista Brasileira de Climatologia**, Online, v. 18, 2021. Disponível em: <https://ojs.ufgd.edu.br/rbclima/article/view/13873>.
- DAHIYA, P. *et al.* Time series study of climate variables utilising a seasonal ARIMA technique for the Indian states of Punjab and Haryana. **Discover Applied Sciences**, Online, v. 6, n. 12, p. 1-16, 29 nov. 2024. https://doi.org/10.1007/s42452-024-06380-5?urlappend=%3Futm_source%3Dresearchgate.net%26utm_medium%3Darticle.



DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root. **Journal of the American Statistical Association**, v. 74, n. 366, p. 427-431, 1979. <https://doi.org/10.2307/2286348>.

DIMRI, T.; AHMAD, S.; SHARIF, M. Time series analysis of climate variables using seasonal ARIMA approach. **Journal Of Earth System Science**, Online, v. 129, n. 1, p. 1-16, 27 jun. 2020. <https://doi.org/10.1007/s12040-020-01408-x>.

FANTIN, M.; WALZBURIECH, D. La Niña confirmado: o que isso significa para o Brasil? **Globo Rural**, São Paulo, 10 jan. 2025. Disponível em: <https://globorural.globo.com/previsao-do-tempo/noticia/2025/01/la-nina-confirmado-o-que-isso-significa-para-o-brasil.ghtml>.

G1. **PR teve o mês de junho mais gelado dos últimos 19 anos, diz Simepar**. G1 Paraná, 15 jul. 2016. Disponível em: <https://g1.globo.com/pr/parana/noticia/2016/07/pr-teve-o-mes-de-junho-mais-gelado-dos-ultimos-19-anos-diz-simepar.html>.

GADDAM, D. C.; JAFARI, R. Temperature forecasting on the Jena Climate dataset using SARIMA and Box–Jenkins models. In: **ARAI, Kohei** (ed.). Proceedings of the Future Technologies Conference (FTC) 2025. Cham: Springer, 2026. p. 320-340. Disponível em: <https://vtechworks.lib.vt.edu/server/api/core/bitstreams/7cf3f4ea-e09c-4cf1-a730-923151b9feb5/content>.

HYNDMAN, R. J. forecast: Forecasting functions for time series and linear models. **Versão 8.21.1**. Melbourne, Austrália: Monash University, 2023. Disponível em: <https://pkg.robjhyndman.com/forecast/>.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2. ed. Melbourne, Australia: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, p. 1-22, 2008. Disponível em: <https://www.jstatsoft.org/article/view/v027i03>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Área territorial brasileira 2022**. Rio de Janeiro: IBGE, 2023. Disponível em: <https://cidades.ibge.gov.br/brasil/pr/francisco-beltrao/panorama>.

INSTITUTO DE DESENVOLVIMENTO RURAL DO PARANÁ. **Resumo Climatológico: Estação Meteorológica Francisco Beltrão 2021a**. Curitiba: IDR – PR, 2021a. Disponível em: https://www.idrparana.pr.gov.br/system/files/publico/agrometeorologia/medias-historicas/Francisco_Beltrao.pdf.

INSTITUTO DE DESENVOLVIMENTO RURAL DO PARANÁ. Boletim Agrometeorológico, julho de 2021. **Instituto de Desenvolvimento Rural do Paraná - IAPAR-EMATER**, 2021b. Disponível em: <https://www.idrparana.pr.gov.br/system/files/publico/agrometeorologia/boletim-agrometeorologico/2021-07.pdf>.

JÚNIOR, E. F.; CASOLA, L. D. R. SECAS NA REGIÃO GEOECONÔMICA CENTRO-SUL DO BRASIL (DE 2020 A 2022): uma discussão teórica. **Revista Foco**, v. 17, n. 10, p. 1-21, 15 out. 2024. <http://dx.doi.org/10.54751/revistafoco.v17n10-061>.



KÖPPEN, Wladimir. Das geographische System der Klimate. In: KÖPPEN, W.; GEIGER, R. (Ed.). **Handbuch der Klimatologie**. Berlin: Gebrüder Borntraeger, 1936. v. 1, p. 1-44. Disponível em: https://koeppen-geiger.vu-wien.ac.at/pdf/Koppen_1936.pdf.

LIMA, C. E. P. Mudanças climáticas e produção de hortaliças: uma visão geral. Brasília, DF: **Embrapa Hortaliças**, 2016. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/921897/1/artigocoluna1.pdf>.

MAKRIDAKIS, S.; SPYRIDAKIS, S. The accuracy of extrapolation (time series) methods: results of a forecasting competition. **Journal of Forecasting**, v. 1, n. 2, p. 111–153, 1982. Disponível em: https://www.researchgate.net/profile/Spyros-Makridakis/publication/245162829_Accuracy_of_Forecasting_An_Empirical_Investigation/links/546641ef0cf25b85d17f5e43/Accuracy-of-Forecasting-An-Empirical-Investigation.pdf

MATA, A. C. O. R. **Aplicação do modelo SARIMA em série do índice de calor na Baixada Cuiabana**. 2019. Dissertação (Mestrado em Ciências Ambientais) – Universidade de Cuiabá, Cuiabá, 2019. Disponível em: <https://repositorio.pgsscogna.com.br/bitstream/123456789/23246/1/Ana%20Cristina%20Oliveira%20Ribeiro%20da%20Mata.pdf>.

MURAT, M. *et al.* Forecasting daily meteorological time series using ARIMA and regression models. **International Agrophysics**, Online, v. 32, n. 2, p. 253-264, 1 abr. 2018. <https://doi.org/10.1515/intag-2017-0007>

NUNES, I. C. **Modelagem e previsão de variáveis climáticas usando modelos SARIMA, VAR e LSTM**. 2025. Trabalho de Conclusão de Curso (Bacharelado em Estatística) – Universidade Federal de Uberlândia, Uberlândia, 2025. Disponível em: <https://repositorio.ufu.br/handle/123456789/47874>

PARANÁ. Sistema de Tecnologia e Monitoramento Ambiental do Paraná. Análise das temperaturas e ocorrência de períodos de calor acima da média no Paraná. Curitiba, [2023]. Disponível em: <https://www.simepar.br/simepar/post/52273>.

PRASAD, Sahana. Time series. In: PRASAD, Sahana. **Advanced statistical methods**. Singapore: Springer, 2024. p. 109–162. DOI: https://doi.org/10.1007/978-981-99-7257-9_3.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, versão 4.4.1, 2024.

RAY, S. *et al.* Time Series SARIMA Modelling and Forecasting of Monthly Rainfall and Temperature in the South Asian Countries. **Earth Systems And Environment**, Online, v. 5, n. 3, p. 531-546, 17 mar. 2021. <https://doi.org/10.1007/s41748-021-00205-w>

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, London, v. 52, n. 3-4, p. 591-611, Dec. 1965. <https://doi.org/10.1093/biomet/52.3-4.591>.

TRAUTTMANN, H.; HORNIK, K. *tseries: Time Series Analysis and Computational Finance*. [S.l.]: R Foundation for Statistical Computing, 2023. Disponível em: <https://CRAN.R-project.org/package=tseries>.

YANG, M. *et al.* A review of spatiotemporal variations in temperature and precipitation: trend analysis, driving mechanisms, and methodological evaluation. **Advances In Resources Research**, [S.L.], v. 4, p. 836-859, 18 out. 2024. http://dx.doi.org/10.50908/arr.4.4_836.

