



Universidade Federal de Uberlândia
Faculdade de Matemática

Bacharelado em Estatística

**AVALIAÇÃO DAS VARIÁVEIS
CLIMÁTICAS: PRECIPITAÇÃO,
TEMPERATURA E UMIDADE
RELATIVA DO AR DA CIDADE DE
FRANCA-SP POR MEIO DE ANÁLISE
DE SÉRIES TEMPORAIS**

Aldenir Martins da Silva Junior

Uberlândia-MG

2026

Aldenir Martins da Silva Junior

**AVALIAÇÃO DAS VARIÁVEIS
CLIMÁTICAS: PRECIPITAÇÃO,
TEMPERATURA E UMIDADE
RELATIVA DO AR DA CIDADE DE
FRANCA-SP POR MEIO DE ANÁLISE
DE SÉRIES TEMPORAIS**

Trabalho de conclusão de curso apresentado à Co-
ordenação do Curso de Bacharelado em Estatística
como requisito parcial para obtenção do grau de
Bacharel em Estatística.

Orientador: Prof^ª. Dra. Nádia Giaretta Biase

Uberlândia-MG

2026



**Universidade Federal de Uberlândia
Faculdade de Matemática**

Coordenação do Curso de Bacharelado em Estatística

A banca examinadora, conforme abaixo assinado, certifica a adequação deste trabalho de conclusão de curso para obtenção do grau de Bacharel em Estatística.

Uberlândia, _____ de _____ de 20_____

BANCA EXAMINADORA

Prof^ª. Dra. Nádia Giaretta Biase

Prof. Dr. Ednaldo Carvalho Guimarães

Prof^ª. Dra. Patrícia Ferreira Paranaíba

**Uberlândia-MG
2026**

AGRADECIMENTOS

Primeiramente, agradeço a Deus, que sempre me sustentou e guiou durante toda essa caminhada, dando-me força e perseverança para chegar até aqui.

À Universidade Federal de Uberlândia, por ter aberto as portas para a minha formação acadêmica.

À minha mãe, Marinilse, que sempre foi e sempre será minha maior incentivadora nos estudos. Tenho certeza de que, de onde ela estiver, está vendo tudo isso.

Ao meu irmão João Paulo e a toda minha família, padrinhos, tios e tias, que de alguma forma contribuíram, apoiaram e acreditaram em mim durante essa jornada.

Aos meus amigos de graduação, em especial ao Joabe e ao Liniker, que estiveram comigo em todos os momentos, compartilhando desafios, aprendizados e conquistas ao longo dessa caminhada.

À minha orientadora, Prof^ª. Dra. Nádia Giaretta Biase, pela orientação, pelos ensinamentos, pela atenção e pela constante disponibilidade em sempre me auxiliar. Agradeço pelo apoio, pela dedicação, pelo compartilhamento de conhecimento e pelas valiosas contribuições ao longo do desenvolvimento deste trabalho.

Ao Prof. Dr. Ednaldo Carvalho Guimarães e à Prof^ª. Dra. Patrícia Ferreira Paranaíba, por aceitarem o convite para compor a banca examinadora e pelas contribuições.

RESUMO

Compreender como as condições climáticas interferem na agricultura é fundamental, especialmente para o cultivo do café, uma das principais atividades econômicas da cidade de Franca-SP, reconhecida por sua relevância na produção cafeeira no Brasil. Nesse contexto, o objetivo deste estudo foi ajustar modelos de séries temporais capazes de prever as variáveis climáticas precipitação mensal, temperatura média e umidade relativa do ar, contribuindo para auxiliar a tomada de decisão de cafeicultores e produtores rurais. Para isso, foram ajustados modelos do tipo SARIMA utilizando dados mensais coletados entre janeiro de 2011 e maio de 2025, realizando previsões para o período de janeiro a maio de 2025. Os critérios de seleção dos modelos foram baseados nos menores valores do Critério de Informação de Akaike (AIC) e do Critério Bayesiano de Schwarz (BIC). O desempenho preditivo foi avaliado por meio das métricas RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MASE (Mean Absolute Scaled Error) e ME (Mean Error). Os resultados indicaram desempenhos distintos para cada variável climática analisada. A precipitação total mensal apresentou desempenho razoável com o modelo SARIMA $(0,0,1)(0,1,1)_{12}$, possivelmente devido à alta variabilidade característica dessa variável. A temperatura média mensal apresentou o melhor desempenho entre as variáveis analisadas com o modelo SARIMA $(1,0,1)(0,1,1)_{12}$, evidenciando alta precisão nas previsões. Já a umidade relativa do ar apresentou resultados satisfatórios com o modelo SARIMA $(0,0,1)(0,1,1)_{12}$, embora com desempenho ligeiramente inferior ao observado para a temperatura. De modo geral, os resultados indicam que modelos da família SARIMA podem ser ferramentas úteis para a previsão de variáveis climáticas, podendo auxiliar no planejamento e na tomada de decisões relacionadas ao manejo da cultura do café.

Palavras-chave: Tendência, Sazonalidade, AIC, SARIMA, Café.

ABSTRACT

Understanding how climatic conditions interfere with agriculture is fundamental, especially for coffee cultivation, one of the main economic activities in the city of Franca-SP, recognized for its relevance in coffee production in Brazil. In this context, the objective of this study was to adjust time series models capable of predicting climatic variables such as monthly precipitation, average temperature, and relative air humidity, contributing to assisting in the decision-making of coffee growers and rural producers. To this end, SARIMA-type models were adjusted using profitable monetary data between January 2011 and May 2025, planned for the period from January to May 2025. The model selection criteria were based on the lowest values of the Akaike Information Criterion (AIC) and the Bayesian Schwarz Criterion (BIC). Predictive performance was evaluated using the metrics RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MASE (Mean Absolute Scaled Error), and ME (Mean Error). The results indicated distinct performances for each climatic variation. The total monthly exception showed reasonable performance with the SARIMA $(0,0,1)(0,1,1)_{12}$ model, possibly due to the high variability characteristic of this variable. The average monthly temperature showed the best performance among the variables tested with the SARIMA $(1,0,1)(0,1,1)_{12}$ model, demonstrating high precision in the isolated variables. Relative air humidity showed superior results with the SARIMA $(0,0,1)(0,1,1)_{12}$ model, although with superior performance compared to temperature. Overall, the results indicate that models from the SARIMA family can be useful tools for forecasting climate variations, potentially assisting in planning and decision-making related to coffee crop management.

Keywords: Trend, Seasonality, AIC, SARIMA, Coffee.

SUMÁRIO

Lista de Figuras	I
Lista de Tabelas	II
1 Introdução	1
2 Fundamentação Teórica	2
2.1 Variáveis Climáticas	2
2.2 Séries Temporais	3
2.3 Tendência e Sazonalidade	3
2.4 Estacionariedade	6
2.5 Modelo ARIMA (AutoRegressive Integrated Moving Average)	6
2.6 Critérios de Seleção do Modelo	9
2.7 Diagnóstico dos Resíduos	10
2.8 Métricas de Avaliação do Modelo	11
3 Metodologia	13
4 Resultados	14
4.1 Análise dos Modelos de Séries Temporais – Precipitação total mensal	16
4.2 Análise dos Modelos de Séries Temporais – Temperatura média mensal	23
4.3 Análise dos Modelos de Séries Temporais – Umidade relativa do ar	29
5 Conclusões	36
Referências Bibliográficas	37

LISTA DE FIGURAS

4.1	Precipitação total mensal, em milímetros, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	15
4.2	Temperatura média mensal, em °C, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	15
4.3	Umidade relativa do ar, em %, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	16
4.4	Precipitação total mensal, em milímetros, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	17
4.5	Função de Autocorrelação (FAC) da precipitação.	18
4.6	Função de Autocorrelação Parcial (FACP) da precipitação.	18
4.7	Função de Autocorrelação (FAC) dos resíduos da precipitação.	19
4.8	Função de Autocorrelação Parcial dos resíduos (FACP) da precipitação.	20
4.9	Resíduos da precipitação.	20
4.10	Previsão para precipitação total mensal, em mm, da cidade de Franca-SP compreendida entre os meses de Janeiro a Maio de 2025.	21
4.11	Valores previstos x valores reais da variável precipitação da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.	22
4.12	Temperatura média mensal, em °C, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	23
4.13	Função de Autocorrelação (FAC) da temperatura.	24
4.14	Função de Autocorrelação Parcial (FACP) da temperatura.	24
4.15	Função de Autocorrelação (FAC) dos resíduos da temperatura.	26
4.16	Função de Autocorrelação Parcial (FACP) dos resíduos da temperatura.	26
4.17	Resíduos da temperatura.	27
4.18	Previsão para temperatura média mensal, em °C, da cidade de Franca-SP, compreendida entre os meses de Janeiro a Maio de 2025.	27
4.19	Valores previstos x valores reais da variável temperatura da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.	28
4.20	Umidade relativa do ar, em %, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.	29
4.21	Função de Autocorrelação (FAC) da umidade.	30
4.22	Função de Autocorrelação Parcial (FACP) da umidade.	30
4.23	Função de Autocorrelação (FAC) dos resíduos da umidade.	32
4.24	Função de Autocorrelação Parcial (FACP) dos resíduos da umidade.	32
4.25	Resíduos da umidade.	33
4.26	Previsão para umidade relativa do ar, em %, compreendida entre os meses de Janeiro a Maio de 2025.	34
4.27	Valores previstos x valores reais da variável umidade da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.	35

LISTA DE TABELAS

4.1	Estatísticas descritivas das variáveis climáticas em estudo.	14
4.2	Estimativas dos parâmetros dos modelos SARIMA ajustados à série de precipitação da cidade de Franca-SP.	19
4.3	Previsão do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de precipitação da cidade de Franca-SP.	22
4.4	Métricas do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de precipitação da cidade de Franca-SP.	22
4.5	Estimativas dos parâmetros dos modelos SARIMA ajustados à série de temperatura da cidade de Franca-SP.	25
4.6	Previsão do Modelo 1 - SARIMA (1,0,1)(0,1,1) para a série de temperatura da cidade de Franca-SP.	28
4.7	Métricas do Modelo 1 - SARIMA (1,0,1)(0,1,1) para a série de temperatura da cidade de Franca-SP.	28
4.8	Estimativas dos parâmetros dos modelos SARIMA ajustados à série de umidade.	31
4.9	Previsão do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de umidade da cidade de Franca-SP.	34
4.10	Métricas do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de umidade da cidade de Franca-SP.	35

1. INTRODUÇÃO

A agricultura é uma atividade diretamente influenciada pelas condições climáticas, sendo essencial compreender como variáveis meteorológicas se comportam ao longo do tempo para auxiliar no planejamento das atividades no campo. Além de sua dependência do clima, a agricultura se destaca como um dos principais pilares do desenvolvimento econômico e social, exercendo papel estratégico no fornecimento de alimentos, na produção de matérias-primas e na geração de empregos.

No município de Franca, localizado no interior do estado de São Paulo, a cafeicultura destaca-se como a principal atividade econômica. Segundo a Companhia Nacional de Abastecimento (CONAB, 2022)[10], a região integra uma das áreas mais relevantes para a produção de café arábica no Brasil, sendo reconhecida pela qualidade do grão e pela tradição histórica da cultura. Nesse contexto, oscilações nos índices de temperatura, regimes de chuva e níveis de umidade relativa do ar exercem influência significativa no cultivo e na produtividade das lavouras. Portanto, compreender como essas variáveis se comportam ao longo do tempo torna-se essencial para a manutenção da produtividade e da competitividade do setor cafeeiro local (CARVALHO, 2008)[7].

A análise de séries temporais surge como uma ferramenta estatística adequada para o estudo de variáveis meteorológicas, uma vez que permite identificar tendências, ciclos e padrões de sazonalidade presentes nos dados históricos (BOX, JENKINS E REINSEL (2016))[6]. Além de possibilitar uma compreensão mais aprofundada do comportamento climático, tais análises oferecem suporte ao desenvolvimento de modelos preditivos, capazes de estimar o comportamento futuro das variáveis em questão. Segundo o Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021)[18], o uso de previsões climáticas e modelos estatísticos representa uma estratégia de grande relevância para a agricultura, pois fornece subsídios para o planejamento de práticas agrícolas, manejo de irrigação, definição de períodos de colheita e redução de riscos relacionados a adversidades climáticas.

Diante do exposto, este trabalho tem como objetivo realizar uma análise de séries temporais dessas variáveis climáticas, utilizando dados históricos coletados na cidade de Franca-SP, permitindo identificar padrões, tendências e sazonalidades que influenciam diretamente nas lavouras. A partir da análise dos dados, busca-se ajustar modelos preditivos que estimem o comportamento futuro das variáveis analisadas. Tais previsões podem auxiliar os agricultores locais na tomada de decisões relacionadas ao manejo da lavoura, planejamento de irrigação, definição de períodos de colheita e prevenção de perdas decorrentes de condições climáticas adversas.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 VARIÁVEIS CLIMÁTICAS

O clima constitui um dos principais fatores determinantes para a produtividade e a qualidade do café, especialmente em Franca-SP, na região da Alta Mogiana, considerada uma das maiores produtoras de café do Brasil. A cidade está localizada a $20^{\circ}32'19''$ de latitude sul e $47^{\circ}24'03''$ de longitude oeste, sendo o clima subtropical de altitude (Cwb) segundo KÖPPEN (2009)[19].

Variáveis climáticas como precipitação mensal, temperatura média e umidade relativa do ar, influenciam diretamente em todas as fases fenológicas da cultura, desde a floração até a maturação dos frutos. Além disso, a distribuição regular das chuvas é essencial, visto que tanto o excesso quanto o déficit hídrico podem comprometer a floração, a granação e a qualidade final do café, causando a redução da produtividade.

Sendo assim, torna-se fundamental avaliar o comportamento dessas variáveis, de modo a subsidiar a tomada de decisões relacionadas à produção cafeeira e de outras culturas. Como essas variáveis são registradas ao longo do tempo, as observações configuram uma sequência temporal, sendo apropriada a utilização de técnicas estatísticas de análise de séries temporais para modelagem e interpretação desses dados.

CHECHI E BAYER (2012)[8] utilizaram modelos de séries temporais para a previsão das temperaturas médias mensais na cidade de Erechim-RS, ajustando modelos da classe ARIMA e modelos de alisamento exponencial. Estudos dessa natureza ressaltam a importância das técnicas de previsão na análise de variáveis climáticas ao longo do tempo.

CINTRA, MELO E BUENO FILHO (2019)[9] também avaliaram os modelos de Box-Jenkins e de suavização exponencial para a série da temperatura média mensal da cidade de Lavras-MG. Eles chegaram a conclusão de que ambos os modelos foram capazes de captar a periodicidade sazonal anual presente nas observações, como também, fornecem boas previsões para a série de temperatura média mensal de Lavras, sugerindo que esses modelos são adequados para a realização deste tipo de análise.

BARBOSA et al. (2017)[3] ajustaram os modelos aditivos de Holt-Winters e SARIMA para temperatura máxima mensal na cidade do Rio de Janeiro (RJ) usando séries temporais. O modelo SARIMA apresentou o melhor ajuste e, portanto, foi adotado para a previsão da temperatura máxima mensal para o ano de 2016.

Nesse contexto, o uso de séries temporais torna-se relevante para a previsão de variáveis

climáticas, como temperatura média, precipitação mensal e umidade relativa do ar, especialmente em regiões cafeeiras como Franca-SP. A aplicação dessas ferramentas estatísticas pode auxiliar produtores de café no planejamento agrícola e na tomada de decisão, minimizando os impactos das variações climáticas sobre a produtividade e a qualidade da cultura.

2.2 SÉRIES TEMPORAIS

Segundo MORETTIN E TOLOI (2006)[21], uma série temporal é qualquer conjunto de observações ordenadas no tempo. Esses dados são dispostos em ordem cronológica, em que cada observação está associada a um instante específico no tempo, sendo registrados de maneira periódica e regular. As séries temporais são ferramentas poderosas e são muito utilizadas para fazer previsões, com aplicações em diversas áreas, tais como vendas, produtividade, inflação e até mesmo na previsão do tempo. Os dados meteorológicos coletados ao longo do tempo são usados para prever o clima futuro.

A suposição básica que orienta a análise de séries temporais é que há um sistema causal relativamente constante, relacionado com o tempo, que influenciou os dados no passado e tende a continuar influenciando no futuro. Esse sistema geralmente se manifesta por meio de padrões não aleatórios que podem ser identificados em um gráfico da série temporal, ou por meio de algum outro processo estatístico.

2.3 TENDÊNCIA E SAZONALIDADE

De acordo com LATORRE E CARDOSO (2001)[20], uma série histórica pode ser composta por três componentes: tendência (T_t), sazonalidade (S_t) e a variação aleatória denominada de ruído branco (a_t).

A tendência é a componente que representa o movimento de longo prazo dos dados, isto é, a direção geral (crescimento, queda ou estabilidade) observada ao longo do tempo, desconsiderando variações sazonais, ciclos e ruído aleatório.

Há vários métodos para estimar a tendência. De acordo com MORETTIN E TOLOI (2006)[21], os mais utilizados consistem em:

- (i) ajustar uma função do tempo, como um polinômio, uma exponencial ou outra função suave de t ;
- (ii) suavizar (ou filtrar) os valores da série ao redor de um ponto, para estimar a tendência naquele ponto;
- (iii) suavizar os valores da série através de sucessivos ajustes de retas de mínimos quadrados ponderados.

Cada um desses métodos possui características e aplicações distintas. O ajuste de uma função do tempo, como polinômios ou funções exponenciais, é indicado quando se deseja representar a tendência por meio de um modelo matemático explícito, sendo útil em análises em que se busca interpretar ou projetar o comportamento da série. Já os métodos de suavização,

como as médias móveis, são mais flexíveis e utilizados quando não se deseja impor uma forma funcional específica para a tendência, sendo ideais para capturar mudanças locais e flutuações de curto prazo. Por sua vez, os métodos baseados em sucessivos ajustes de retas de mínimos quadrados ponderados, como as técnicas de suavização local, são especialmente úteis em séries com comportamentos mais complexos, pois permitem que a tendência se adapte às mudanças estruturais presentes nos dados.

Dentre os testes para a verificação da presença de tendência em uma série temporal, neste estudo, optou-se pela utilização do teste de Cox-Stuart.

O teste de Cox-Stuart é um teste não paramétrico utilizado para identificar tendências (crescentes ou decrescentes) em uma série temporal ou sequência de dados. Para a realização do teste, de acordo com COX E STUART (1955)[11], as observações são agrupadas em pares $(Z_1, Z_{1+c}), (2, Z_{2+c}), \dots, (Z_{N-c}, Z_N)$, em que $c = \frac{N}{2}$, se N for par, e $c = \frac{N+1}{2}$, se N for ímpar. A cada par (Z_i, Z_{i+c}) associamos o sinal $+$ se $Z_i < Z_{i+c}$ e o sinal $-$ se $Z_i > Z_{i+c}$, eliminando os empates. Seja n o número de pares onde $Z_i \neq Z_{i+c}$.

Desejamos testar:

$$H_0 : P(Z_i < Z_{i+c}) = P(Z_i > Z_{i+c}), \forall i \quad (\text{Não existe tendência});$$

$$H_1 : P(Z_i < Z_{i+c}) \neq P(Z_i > Z_{i+c}), \forall i \quad (\text{Existe tendência}).$$

Este é um teste bilateral. Um teste unilateral para testar H_0 : não existe tendência positiva contra H_1 : existe tendência positiva, é obtido substituindo “=” por “ \leq ” e “ \neq ” por “ $>$ ”, respectivamente, em H_0 e H_1 , definidas anteriormente.

Seja T_2 o número de pares com sinal $+$. Então, para $n \leq 20$, a regra de decisão é baseada na distribuição binomial e, para $n > 20$, pode-se utilizar a aproximação normal.

Considerando o teste unilateral mencionado acima, valores grandes de T_2 indicam que é mais provável que $+$ ocorra, e, portanto, rejeita-se H_0 se $T_2 \geq n - t$, onde t é obtido em uma tabela da distribuição binomial com parâmetros $p = \frac{1}{2}$ e n , para um dado nível de significância α .

Segundo MORETTIN E TOLOI (2006)[21], são considerados como sazonais eventos que ocorrem regularmente de ano para ano. Esse componente sazonal está relacionado a padrões periódicos fixos, como meses, trimestres ou estações do ano, como por exemplo:

- Vendas mensais de brinquedos no mês de dezembro e de chocolates na Páscoa;
- Aumento da ocupação hoteleira durante as férias escolares;
- Maior consumo de energia elétrica em dias quentes (ar-condicionado);
- Aumento no consumo de sorvete no verão.

Existem diversas formas de se estimar S_t , sendo as mais utilizadas:

- **Método de regressão - (sazonalidade determinística):** modela padrões sazonais fixos e repetitivos em séries temporais usando variáveis indicadoras (dummies) ou funções trigonométricas (seno/cosseno) do tempo. Por apresentar comportamento regular e repetitivo, a componente sazonal pode ser prevista com base nos padrões observados em períodos anteriores.
- **Método de médias móveis – (sazonalidade estocástica):** Esse método é indicado para séries temporais em que a componente sazonal varia ao longo do tempo, isto é, quando a sazonalidade apresenta comportamento estocástico e pode variar de um período para outro.

O teste de Fisher é amplamente utilizado para verificar a presença de sazonalidade em séries temporais. Esse teste tem como objetivo identificar a existência de uma frequência periódica significativa que se destaque em relação ao ruído aleatório presente na série. Sua aplicação baseia-se na análise espectral, por meio do periodograma, que permite examinar a distribuição da variância da série em diferentes frequências. De acordo com PRIESTLEY (1989)[23], este teste é realizado com base nas seguintes hipóteses:

$$\begin{cases} H_0 : \text{a série temporal não possui um componente periódico, indicando ausência de sazonalidade;} \\ H_1 : \text{a série temporal possui um componente periódico, indicando a presença de sazonalidade.} \end{cases}$$

Caso o p-valor for menor que o nível de significância (ex: 0,05), rejeita-se a hipótese de nulidade, concluindo-se pela presença de sazonalidade.

A estatística de Fisher é dada por:

$$g = \frac{\max I_s}{\sum_{s=1}^{n/2} I_s}, \quad (2.1)$$

em que $I(s)$ representa valor do periodograma da série temporal na frequência s e n é o número de observações da série.

O periodograma $I(s)$ é dado por:

$$I(s) = \frac{1}{2\pi n} \left| \sum_{t=1}^n x_t e^{-ist} \right|^2, \quad (2.2)$$

onde x_t é a série temporal observada no instante t e n é o número de observações da série.

Valores elevados de g indicam que uma frequência específica concentra grande parte da energia espectral nas frequências sazonais, sugerindo a presença de um componente sazonal significativo na série temporal. Por outro lado, valores baixos de g indicam ausência de dominância sazonal relevante.

O valor crítico de Z_α é dado por:

$$Z_\alpha = 1 - \left(\frac{\alpha}{2} \right)^{\frac{1}{(n/2)-1}}, \quad (2.3)$$

em que α representa o nível de significância do teste e n é o número de observações da série temporal.

A hipótese nula de ausência de sazonalidade é rejeitada quando $g > Z_\alpha$. Caso contrário, não há evidências estatísticas suficientes para afirmar a presença de sazonalidade significativa na série temporal.

2.4 ESTACIONARIEDADE

Uma das suposições mais frequentes que se faz respeito de uma série temporal é a de que ela é estacionária, ou seja, ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável, conforme NIELSEN (2021)[22]. Contudo, na prática, observa-se que a maior parte das séries temporais apresenta algum nível de não estacionariedade. Uma série pode apresentar estacionariedade ao longo de um período extenso ou apenas em intervalos curtos, nos quais ocorrem mudanças de nível e/ou inclinação.

Como grande parte dos procedimentos de análise estatística de séries temporais pressupõe a estacionariedade, torna-se necessário transformar os dados originais quando estes não constituem uma série estacionária. De acordo com MORETTIN E TOLOI (2006)[21], a transformação mais utilizada consiste na aplicação de diferenças sucessivas à série original, até que se obtenha uma série estacionária. A primeira diferença $Z(t)$ é definida por:

$$\Delta Z(t) = Z(t) - Z(t - 1)$$

a segunda diferença é

$$\Delta^2 Z(t) = \Delta[\Delta Z(t)] = \Delta Z(t) - Z(t - 1)$$

ou seja,

$$\Delta^2 Z(t) = Z(t) - 2Z(t - 1) + Z(t - 2).$$

De modo geral, a n -ésima diferença de $Z(t)$ é

$$\Delta^n Z(t) = \Delta [\Delta^{n-1} Z(t)]$$

Em condições usuais, quando a série apresenta tendência e/ou sazonalidade, uma ou duas diferenças costumam ser suficientes para tornar a série estacionária.

2.5 MODELO ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE)

Para diversas séries observadas na prática, quando se deseja utilizar um modelo com um número moderado de parâmetros, a inclusão de componentes autorregressivos e de médias

móveis costuma ser uma alternativa apropriada (MORETTIN E TOLOI, 2006)[21]. Nesse contexto, surgem os modelos ARMA(p, q) (AutoRegressive Moving Average), que combinam componentes autorregressivos (AR) e de médias móveis (MA), sendo particularmente adequados para séries temporais estacionárias.

De forma geral, o modelo ARMA(p, q) pode ser expresso como:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}. \quad (2.4)$$

Um processo AR(p) apresenta uma função de autocorrelação (FAC) que se estende infinitamente, decaindo segundo um padrão exponencial e/ou na forma de senóides amortecidas.

Já um processo MA(q) possui FAC finita, isto é, ela apresenta um corte após o lag q .

Por sua vez, um processo ARMA(p, q) apresenta uma FAC infinita em extensão, que passa a decair de acordo com exponenciais e/ou senóides amortecidas a partir do lag $q - p$.

Contudo, muitas séries temporais observadas na prática apresentam comportamento não estacionário, o que limita a aplicação direta dos modelos ARMA. Para contornar essa limitação, utiliza-se o modelo ARIMA (AutoRegressive Integrated Moving Average), proposto por Box e Jenkins, que incorpora o processo de diferenciação à estrutura ARMA, permitindo a modelagem de séries não estacionárias.

O modelo ARIMA é uma das metodologias mais utilizadas na análise e previsão de séries temporais, sendo baseado na combinação de componentes autorregressivos, de diferenciação e de médias móveis, conforme BOX, JENKINS E REINSEL (2015)[6]. Além disso, o ARIMA é especialmente eficaz quando a série apresenta autocorrelação e não estacionariedade.

A estratégia para a construção do modelo é baseada em um ciclo iterativo composto por quatro etapas principais: especificação, identificação, estimação e verificação. Inicialmente, na etapa de especificação, define-se uma classe geral de modelos adequada à série temporal em análise. Em seguida, na fase de identificação, são examinadas as funções de autocorrelação (FAC) e autocorrelação parcial (FACP), além de outros critérios estatísticos, com o objetivo de determinar as ordens apropriadas do modelo. Posteriormente, realiza-se a estimação, etapa na qual os parâmetros do modelo previamente identificado são estimados por métodos estatísticos adequados. Por fim, procede-se à verificação, que consiste na análise dos resíduos do modelo ajustado, a fim de avaliar sua adequação e verificar se estes se comportam como ruído branco, condição essencial para a realização de previsões confiáveis, conforme descrito na metodologia de BOX, JENKINS E REINSEL (2015)[6].

De forma geral, o ARIMA é representado por ARIMA(p, d, q), onde:

- p : ordem autorregressiva (AR);
- d : número de diferenciações;
- q : ordem da média móvel (MA).

Componente Autorregressivo (AR)

A parte autorregressiva indica que o valor atual da série depende de seus valores passados. Em termos matemáticos, o modelo AR(p) utiliza defasagens da própria série como variáveis explicativas.

De acordo com GUJARATI E PORTER (2011)[13], modelos autorregressivos são adequados quando há forte dependência temporal entre observações consecutivas.

Componente de Integração/Diferenciação (I)

O termo “*Integrated*” refere-se ao processo de diferenciação da série temporal para torná-la estacionária. Segundo ENDERS (2014)[12], a diferenciação é aplicada quando a série apresenta tendência ou comportamento não estacionário.

Componente de Média Móvel (MA)

A parte de média móvel modela o erro da série como função de erros passados, capturando choques aleatórios que influenciam o comportamento da variável ao longo do tempo. Conforme descrito por HAMILTON (1994)[14], o componente MA(q) permite corrigir flutuações imprevisíveis presentes na série temporal.

A formulação geral do modelo ARIMA pode ser expressa por:

$$\phi(B)(1 - B)^d Z_t = \theta(B)\varepsilon_t, \quad (2.5)$$

em que:

- Z_t é o valor da série temporal no instante t ;
- B é o operador de defasagem (backshift), tal que $BZ_t = Z_{t-1}$;
- $(1 - B)^d$ é o operador de diferenciação de ordem d ;
- $\phi(B)$ é o polinômio autorregressivo (AR) de ordem p ;
- $\theta(B)$ é o polinômio de média móvel (MA) de ordem q ;
- ε_t é o termo de erro aleatório (ruído branco).

O polinômio autorregressivo, denotado por AR(p), é definido como:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p. \quad (2.6)$$

E o polinômio de média móvel, MA(q) pode ser escrito como:

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q. \quad (2.7)$$

Quando a série temporal apresenta comportamento sazonal, utiliza-se o modelo SARIMA (Seasonal AutoRegressive Integrated Moving Average), representado por SARIMA(p, d, q)(P, D, Q) $_s$, que incorpora componentes sazonais ao modelo ARIMA tradicional.

A forma geral do modelo SARIMA é dada por:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D Z_t = \Theta(B^s)\theta(B)\varepsilon_t, \quad (2.8)$$

em que:

- Z_t representa o valor da série temporal no instante t ;
- B é o operador de defasagem, definido por $B^k Z_t = Z_{t-k}$;
- $\phi(B)$ é o polinômio autorregressivo não sazonal de ordem p , dado por $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$;
- $\theta(B)$ é o polinômio de média móvel não sazonal de ordem q , definido por $\theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$;
- $\Phi(B^s)$ é o polinômio autorregressivo sazonal $\text{AR}(p)$;
- $\Theta(B^s)$ é o polinômio de média móvel sazonal $\text{MA}(q)$;
- $(1-B)^d$ representa o operador de diferenciação não sazonal de ordem d ;
- $(1-B^s)^D$ corresponde ao operador de diferenciação sazonal de ordem D e periodicidade s ;
- ε_t é o termo de erro aleatório (ruído branco), assumido com média zero, variância constante e ausência de autocorrelação.

2.6 CRITÉRIOS DE SELEÇÃO DO MODELO

Os critérios de seleção AIC (*Akaike Information Criterion*) e BIC (*Bayesian Information Criterion*), são amplamente utilizados na seleção de modelos estatísticos, incluindo modelos de séries temporais. Esses critérios têm como objetivo comparar diferentes especificações de modelos com base no equilíbrio entre qualidade de ajuste e complexidade. De modo geral, a escolha do modelo mais adequado é realizada com base no menor valor do critério de informação, uma vez que valores menores indicam melhor ajuste aos dados (HYNDMAN E ATHANASOPOULOS, 2021)[16].

Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike (AIC) é uma métrica estatística fundamental na análise e modelagem de séries temporais para selecionar o melhor modelo entre vários candidatos. Ele equilibra a qualidade do ajuste do modelo (quão bem ele explica os dados) com a sua simplicidade, penalizando modelos excessivamente complexos para evitar o sobreajuste.

Sua formulação geral é dada por:

$$AIC = -2 \ln(L) + 2k, \quad (2.9)$$

em que L representa a máxima verossimilhança do modelo ajustado e k é o número de parâmetros estimados (AKAIKE, 1974)[1].

Critério de Informação Bayesiano (BIC)

O Critério de Informação Bayesiano (BIC), proposto por SCHWARZ (1978)[24], é um critério de seleção de modelos baseado na verossimilhança que penaliza modelos complexos (com muitos parâmetros), sendo amplamente utilizado na comparação de modelos de séries temporais, especialmente na modelagem ARIMA.

Sua formulação pode ser escrita por:

$$BIC = -2 \ln(L) + k \ln(n), \quad (2.10)$$

em que L representa a máxima verossimilhança do modelo ajustado, k é o número de parâmetros estimados e n corresponde ao tamanho da amostra.

2.7 DIAGNÓSTICO DOS RESÍDUOS

Após estimar o modelo, é necessário verificar se ele representa, ou não, adequadamente os dados (MORETTIN E TOLOI, 2006)[21]. Uma etapa essencial dessa verificação é o diagnóstico dos resíduos, ou seja, analisar os erros entre os valores observados e os valores ajustados pelo modelo.

Os resíduos e_t são definidos como:

$$e_t = Y_t - \hat{Y}_t, \quad (2.11)$$

onde Y_t representa o valor observado no instante t e \hat{Y}_t o valor estimado pelo modelo.

A principal hipótese em muitos modelos de séries temporais é que, após o ajuste, estes resíduos se comportem como um ruído branco, ou seja, que sejam: com média zero, com variância constante e sem autocorrelação serial significativa. O motivo dessa exigência é conceitual: se o modelo capturou toda a estrutura temporal explicável da série (tendência, sazonalidade, autocorrelação), os resíduos restantes devem ser aleatórios e imprevisíveis. Caso contrário, existem padrões nos resíduos que ainda poderiam ser modelados, indicando que o modelo não é totalmente adequado para os dados.

Dentre as ferramentas de diagnóstico dos resíduos, tem-se a análise da FAC e FACP dos Resíduos. Nesse caso, uma verificação visual importante é o gráfico da Função de Autocorrelação (ACF) e da Função de Autocorrelação Parcial (FACP) dos resíduos. Enquanto a FAC avalia a autocorrelação total entre os resíduos em diferentes lags, a FACP mede a autocorrelação direta, controlando o efeito dos lags intermediários. Se os resíduos forem ruído branco, os valores de autocorrelação em diferentes lags devem estar próximos de zero e dentro dos intervalos de confiança (HYNDMAN, 2021)[16].

A adequação dos resíduos, também, pode ser avaliada por meio do teste de Box-Pierce. Conforme BOX E PIERCE (1970)[5], o teste de Box-Pierce é um teste estatístico utilizado

para verificar se existe autocorrelação nos resíduos de um modelo de séries temporais. Assim como o teste de Ljung-Box, ele testa se os resíduos se comportam como ruído branco, ou seja: são independentes, não possuem autocorrelação serial e com média aproximadamente zero.

Suas hipóteses são:

$$\begin{cases} H_0 : \text{os resíduos são não autocorrelacionados (comportam-se como ruído branco);} \\ H_1 : \text{existe autocorrelação remanescente nos resíduos.} \end{cases}$$

Um p-valor maior que o nível de significância (por exemplo, 0,05) sugere que não há evidência estatística de autocorrelação, indicando bom sinal de que o modelo está ajustado adequadamente.

Por fim, testes de normalidade dos resíduos podem ser aplicados. Além da ausência de autocorrelação, muitas abordagens também verificam se os resíduos são aproximadamente normalmente distribuídos. Testes de normalidade (como Shapiro-Wilk ou Jarque-Bera) ou gráficos QQ podem ser usados para essa finalidade, sobretudo se a suposição de normalidade for relevante para a inferência estatística.

2.8 MÉTRICAS DE AVALIAÇÃO DO MODELO

De forma geral, as métricas de avaliação de modelos têm como objetivo quantificar o desempenho das previsões geradas, permitindo comparar os valores previstos com os valores observados. Essas métricas são fundamentais para verificar o quão bem o modelo é capaz de capturar padrões dos dados e produzir previsões confiáveis. Além disso, elas auxiliam na comparação entre diferentes modelos, possibilitando a seleção daquele que apresenta melhor desempenho segundo critérios específicos.

Raiz do Erro Quadrático Médio (RMSE)

Segundo HYNDMAN E ATHANASOPOULOS (2021)[16], O RMSE é definido como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}, \quad (2.12)$$

em que Y_t representa o valor observado no instante t , \hat{Y}_t o valor previsto pelo modelo e n o número total de observações consideradas na avaliação. O RMSE é uma medida que quantifica o tamanho médio do erro cometido pelo modelo ao prever uma variável, na mesma unidade da variável em questão.

Erro Absoluto Médio (MAE)

O MAE, conforme HYNDMAN E ATHANASOPOULOS (2021)[16], pode ser expresso como:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|, \quad (2.13)$$

onde y_t representa o valor observado no tempo t , \hat{y}_t representa o valor previsto pelo modelo no tempo t e n é o número total de observações. O MAE calcula a média das diferenças absolutas entre os valores previstos e reais, indicando o erro médio na mesma unidade dos dados.

Erro Médio (ME)

De acordo com HYNDMAN E ATHANASOPOULOS (2021)[16], a fórmula do ME é dada por:

$$ME = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t), \quad (2.14)$$

em que y_t representa o valor observado no tempo t , \hat{y}_t representa o valor previsto pelo modelo no tempo t e n é o número total de observações. O ME é utilizado principalmente para identificar o viés do modelo.

- $ME > 0$: O modelo tende a subestimar os valores reais (as previsões são, em média, menores que o real);
- $ME < 0$: O modelo tende a superestimar os valores reais (as previsões são, em média, maiores que o real);
- $ME = 0$: Indica que o modelo é, em média, não enviesado, embora isso não signifique que ele seja preciso (pode haver erros grandes que se anulam).

Erro Médio Absoluto Escalonado (MASE)

Como proposto por HYNDMAN E KOEHLER (2006)[15], o MASE é dado por:

$$MASE = \frac{MAE_{\text{modelo}}}{MAE_{\text{ingênuo}}}. \quad (2.15)$$

É uma métrica muito usada na avaliação de modelos de previsão, uma vez que resolve problemas comuns que outras métricas como o MAPE (Erro Médio Percentual Absoluto) não resolvem, como por exemplo quando os dados contêm valores zerados.

O MASE compara o erro do seu modelo com o erro de um modelo ingênuo (feito sobre os dados de treino), aquele que simplesmente prevê que o próximo valor será igual ao anterior.

- $MASE < 1$: O modelo é melhor que o modelo ingênuo. Significa que sua inteligência/ algoritmo está agregando valor real;
- $MASE = 1$: O modelo é igual ao modelo ingênuo;
- $MASE > 1$: O modelo é pior que a modelo ingênuo. Provavelmente não vale a pena usá-lo.

3. METODOLOGIA

Os dados utilizados na pesquisa foram coletados diretamente do site oficial do Instituto Nacional de Meteorologia (INMET). Os arquivos extraídos apresentam registros mensais organizados em planilhas.

A amostra é composta por dados mensais referentes a três variáveis meteorológicas: precipitação mensal, temperatura média e umidade relativa do ar, da cidade de Franca-SP, abrangendo o período de janeiro de 2011 a maio de 2025, totalizando 173 observações de cada série.

O tratamento inicial dos dados envolveu a organização, limpeza e verificação da consistência das informações coletadas. Em seguida, foram elaboradas análises descritivas para compreender o comportamento histórico das variáveis, incluindo a identificação de tendências, padrões sazonais e possíveis anomalias.

Na etapa seguinte, foram ajustados modelos de séries temporais adequados às características de cada variável, com destaque para modelos do tipo ARIMA. O critério de seleção dos modelos considerou aspectos como a estacionariedade da série, análise do correlograma (ACF/PACF) e desempenho nos ajustes iniciais.

Para validação dos modelos ajustados, foram utilizadas métricas estatísticas de desempenho, como o RMSE (*Root Mean Squared Error*), o MAE (*Mean Absolute Error*), o MASE (*Mean Absolute Scaled Error*) e o ME (*Mean Error*) aplicadas sobre os dados de teste. O objetivo desta etapa foi verificar a capacidade preditiva dos modelos e sua adequação às séries analisadas. Os critérios para a escolha dos modelos foram baseados na seleção dos menores valores de AIC e BIC.

Após a escolha dos modelos, foram realizadas as previsões para os meses de Janeiro a Maio de 2025. As análises foram conduzidas utilizando o software estatístico R (IHAKA E GENTLEMAN, 1993)[17], ferramenta reconhecida para análise de séries temporais e previsão.

4. RESULTADOS

Inicialmente, foi realizada a estatística descrita das variáveis precipitação mensal (mm), temperatura média ($^{\circ}\text{C}$) e umidade relativa do ar (%). Estes resultados são apresentados na Tabela 4.1.

Tabela 4.1: Estatísticas descritivas das variáveis climáticas em estudo.

Variável	Precipitação Mensal (mm)	Temperatura Média ($^{\circ}\text{C}$)	Umidade Relativa do Ar (%)
Média	135,46	21,87	66,56
Desvio Padrão	119,21	1,86	10,75
Mínimo	0	17,1	36,5
Máximo	480,8	26,1	86,1
CV	88	8,54	16,15
Curtose	2,41	2,60	2,45
Assimetria	0,62	-0,33	-0,33

A precipitação apresentou uma média de 135,46 mm, com desvio padrão relativamente alto (119,21 mm), indicando grande variabilidade nos valores mensais. O mínimo observado foi 0 mm, enquanto o máximo chegou a 480,8 mm, mostrando que há meses extremamente secos e outros com chuvas intensas. O coeficiente de variação (CV) de 88% confirma essa grande dispersão relativa. A assimetria positiva (0,62) indica que a distribuição é levemente assimétrica à direita, ou seja, eventos de chuva muito intensa são menos frequentes, mas elevam significativamente a média. A temperatura apresentou média de 21,87 $^{\circ}\text{C}$, com desvio padrão de 1,86 $^{\circ}\text{C}$, mostrando que a variação mensal da temperatura é relativamente pequena. Os valores mínimos e máximos foram 17,1 $^{\circ}\text{C}$ e 26,1 $^{\circ}\text{C}$, respectivamente, indicando um clima relativamente estável ao longo do ano. A umidade apresentou média de 66,56%, com desvio padrão de 10,7%, indicando moderada variabilidade ao longo do período. Os valores mínimo e máximo foram 36,5% e 86,1%, evidenciando que em alguns meses o ar pode ficar relativamente seco, enquanto, em outros é mais úmido.

A seguir, serão apresentadas as Figuras 4.1, 4.2 e 4.3, que exibem, respectivamente, a precipitação total mensal, a temperatura média mensal e a umidade relativa do ar entre os anos de 2011 e 2024.

De uma maneira geral, observa-se na Figura 4.1 que a série apresenta uma sazonalidade bem definida, em que é possível identificar durante todo esse período maiores volumes de precipitação entre novembro e março, correspondente às estações do ano primavera-verão, redução acentuada entre maio e setembro, típico do período inverno, e ainda, nos meses de junho, julho e agosto os menores índices acumulados. Além disso, é importante ressaltar que apesar do padrão sazonal semelhante, há variação entre os anos, ou seja, alguns anos apresentam picos muito elevados

com valores de precipitação acima de 400mm em determinados meses (aproximadamente em novembro de 2018), enquanto outros anos verificam-se totais mais moderados.

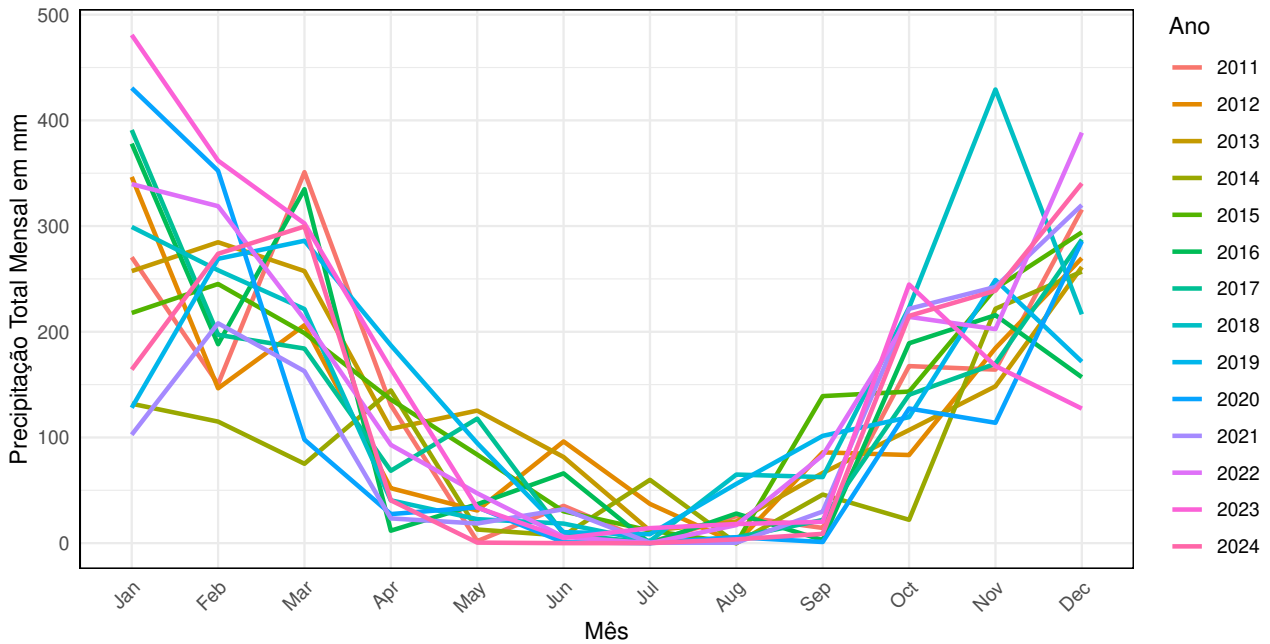


Figura 4.1: Precipitação total mensal, em milímetros, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

Já na Figura 4.2, verifica-se também que a série possui uma sazonalidade bem determinada, onde é possível identificar temperaturas mais altas entre setembro e março, justamente na época de verão, e queda progressiva a partir de abril. Junho e julho apresentam os menores valores médios (aproximadamente 17–19°C). Vale ressaltar também que existem alguns anos com picos mais elevados na primavera e alguns anos mais quentes no inverno (como em 2024, por exemplo).




Figura 4.2: Temperatura média mensal, em °C, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

Em relação à Figura 4.3, observa-se que a sazonalidade da umidade relativa do ar em Franca-SP é bastante evidente (valores abaixo de 45%), com períodos bem definidos de maior e menor umidade ao longo do ano. Em alguns anos, destacam-se mínimos mensais bastante acentuados (por exemplo, em Setembro de 2024), indicando uma estação seca expressiva, que tende a se concentrar nos meses de inverno. Essa variabilidade sazonal pode exercer influência direta sobre as atividades agrícolas, na disponibilidade de recursos hídricos e até mesmo aspectos relacionados à saúde pública, especialmente em períodos prolongados de estiagem.




Figura 4.3: Umidade relativa do ar, em %, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

A precipitação e a umidade estão positivamente correlacionadas: meses com maior precipitação têm maior umidade relativa. Já em relação à temperatura, observa-se que os meses mais frios tendem a ser mais secos, com menor precipitação e umidade relativa. Em contrapartida, durante os meses mais quentes, há aumento das chuvas, acompanhado por níveis mais elevados de umidade. O padrão sazonal indica um clima tipicamente tropical/subtropical, com estação seca no meio do ano e estação chuvosa no início e fim do ano.

4.1 ANÁLISE DOS MODELOS DE SÉRIES TEMPORAIS — PRECIPITAÇÃO TOTAL MENSAL

Inicialmente, na Figura 4.4, foi plotada a série original da variável precipitação total mensal (em mm), no período de maio de 2011 a dezembro de 2024. Nota-se, claramente, a presença de picos recorrentes de precipitação a cada 12 meses, evidenciando forte sazonalidade ao longo de todo o período analisado. Em contrapartida, parece não haver tendência linear clara de aumento, como também não há redução consistente ao longo dos anos.




Figura 4.4: Precipitação total mensal, em milímetros, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

A estrutura da Função de Autocorrelação (FAC), apresentada na Figura 4.5, é mais um indício de que a série de precipitação apresenta sazonalidade. A alternância entre as correlações positivas e negativas ao longo dos lags reflete a transição entre estações chuvosa e seca, característica típica de séries de precipitações sazonais. Ademais, como todos os lags estão acima da área tracejada, são lags significativos, a série não é estacionária (não oscila em torno de uma constante), portanto, a série não pode ser considerada ruído branco.

Na função de autocorrelação parcial (FACP), apresentada na Figura 4.6 observa-se que apenas o primeiro lag apresenta autocorrelação parcial significativa. Após esse lag, a maioria das correlações estão dentro do intervalo de confiança de 95%, o que sugere uma estrutura autorregressiva de baixa ordem.

Para confirmar a presença das componentes na série por meio de testes estatísticos, foi aplicado o teste de tendência de Cox-Stuart. Para este teste, obteve-se um p-valor de 0,5856, que é superior a 5%, comprovando que não há evidências da presença de tendência na série. ALBUQUERQUE (2019)[2] também chegou a essa conclusão, de não existência de tendência, ao ajustar modelos de séries temporais a dados de precipitação de três municípios do estado de Pernambuco, no Brasil.

Além disso, foi realizado o teste de Fisher para verificar a presença de sazonalidade. O teste resultou em um valor de $p < 0,0001$, muito inferior a 5%, donde há evidências de que a série apresenta sazonalidade.




Figura 4.5: Função de Autocorrelação (FAC) da precipitação.




Figura 4.6: Função de Autocorrelação Parcial (FACP) da precipitação.

Na sequência, para o ajuste dos modelos, foi usado a função *auto.arima*, e com base nos modelos sugeridos foram avaliados alguns modelos apropriados, que são apresentados na Tabela 4.2.

Tabela 4.2: Estimativas dos parâmetros dos modelos SARIMA ajustados à série de precipitação da cidade de Franca-SP.

Modelo	Parâmetro	Estimativa	Erro padrão	p-valor	AIC	BIC
SARIMA (0,0,0)(1,1,2) ₁₂	Φ_1	0,53342	0,21449	0,01288	1778,92	1791,11
	Θ_1	-1,54253	0,21408	< 0,00000		
	Θ_2	0,68535	0,18648	0,00023		
SARIMA (0,0,1)(0,1,1) ₁₂	θ_1	0,15397	0,07779	0,04777	1778,45	1787,59
	Θ_2	-0,88542	0,09049	< 0,00000		
SARIMA (1,0,1)(1,1,0) ₁₂	ϕ_1	0,78846	0,11824	< 0,00000	1816,91	1829,11
	θ_1	-0,52749	0,06881	< 0,00000		
	Φ_1	-0,62417	0,14426	< 0,00000		

Todos os parâmetros dos modelos foram significativos ao nível de 5%. O Modelo 2 apresentou os melhores resultados, com AIC = 1.778,45 e BIC = 1.787,59, sendo os menores valores entre os três modelos avaliados, portanto o mais adequado para representar a série. Em seguida, realizou-se a análise dos resíduos desse modelo.

Nas Figuras 4.7 e 4.8 são apresentadas as funções de autocorrelação e autocorrelação parcial dos resíduos. Em ambas, observa-se a ausência de mais de 2 lags significativos, indicando que os resíduos não são correlacionados e que o modelo capturou adequadamente a estrutura temporal da série.




Figura 4.7: Função de Autocorrelação (FAC) dos resíduos da precipitação.

Após essa análise, foi aplicado o teste de Box-Pierce para confirmação de que os resíduos segue uma distribuição normal. Nesse caso, foi encontrado um p-valor igual a 0,9669, o que indica que a hipótese nula de que os resíduos são normalmente distribuídos não pode ser rejeitada. Portanto os resíduos seguem um comportamento de ruído branco, validando a adequação do modelo para fins de análise e previsão.




Figura 4.8: Função de Autocorrelação Parcial dos resíduos (FACP) da precipitação.

O gráfico Q-Q dos resíduos, apresentado na Figura 4.9, indica aderência satisfatória à distribuição normal, reforçando, mais uma vez, a ideia do comportamento de ruído branco. Em conjunto com a ausência de autocorrelação significativa nos resíduos, os resultados confirmam a adequação estatística do modelo ajustado.




Figura 4.9: Resíduos da precipitação.

Na Figura 4.10 são apresentadas as previsões para a precipitação total mensal (em mm) da cidade de Franca-SP. A projeção da precipitação mensal para o período de janeiro a maio de 2025 indica manutenção do padrão sazonal característico da série histórica, com maiores acumulados previstos nos meses iniciais do ano e redução gradual até maio. Os resultados são coerentes com a estrutura temporal identificada e validada nas etapas anteriores da análise.




Figura 4.10: Previsão para precipitação total mensal, em mm, da cidade de Franca-SP compreendida entre os meses de Janeiro a Maio de 2025.

As estimativas dos valores previstos, os valores reais, o erro de previsão e os limites inferiores e superiores do intervalo de confiança de 95% são apresentadas na Tabela 4.3 para o período compreendido entre janeiro a maio de 2025. Os valores estimados foram comparados aos valores reais, afim de avaliar a acurácia do modelo SARIMA ajustado por meio das diferenças observadas. O modelo SARIMA apresentou desempenho satisfatório, visto que todos os valores reais permaneceram dentro do intervalo de confiança estimado. No entanto, observa-se uma tendência à superestimativa da precipitação, possivelmente associada à ocorrência de condições atmosféricas atípicas no período analisado. O melhor desempenho foi observado no mês de abril, com erro praticamente nulo. Esses resultados também foram apresentados, para melhor compreensão da análise, na Figura 4.11.

Considerando a elevada variabilidade da precipitação mensal, o valor do RMSE de 64,5 mm é compatível com a escala da série analisada, enquanto o MAE de 46,6 mm representa o erro absoluto médio, fornecendo uma medida mais direta da acurácia do modelo, o que pode ser observado na Tabela 4.4. O erro médio (ME) de 2,5 mm sugere um leve viés de subestimação da precipitação no conjunto de treino, embora de pequena magnitude. O MASE igual a 0,6

indica que o modelo apresenta desempenho superior ao de uma previsão ingênua, evidenciando sua capacidade preditiva. O MAPE não foi considerado adequado devido à presença de valores iguais a zero na série de precipitação, o que torna essa métrica indefinida.

Tabela 4.3: Previsão do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de precipitação da cidade de Franca-SP.

Mês	Valor Previsto	Valor Real	Erro	Limite Inferior IC 95%	Limite Superior IC 95%
Jan/2025	295,9	258,6	-37,3	164,1	427,6
Fev/2025	256,9	132,1	-124,8	123,6	390,2
Mar/2025	231,1	112,8	-118,3	97,8	364,4
Abr/2025	85,7	85,8	0,1	-47,5	219,0
Mai/2025	43,0	18,4	-24,6	-90,2	176,3

Tabela 4.4: Métricas do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de precipitação da cidade de Franca-SP.

RMSE	MAE	ME	MASE
64,535	46,634	2,578	0,629

BORGES et al. (2025)[4] encontraram resultados bem próximos de RMSE (76,87) E MAE (57,52) ao ajustar modelos ARIMA para a série temporal de precipitação mensal em Areia-PB. Isso indica que modelos da família ARIMA/SARIMA podem ser apropriados para a modelagem e previsão de séries temporais climáticas, especialmente quando há presença de componentes sazonais.

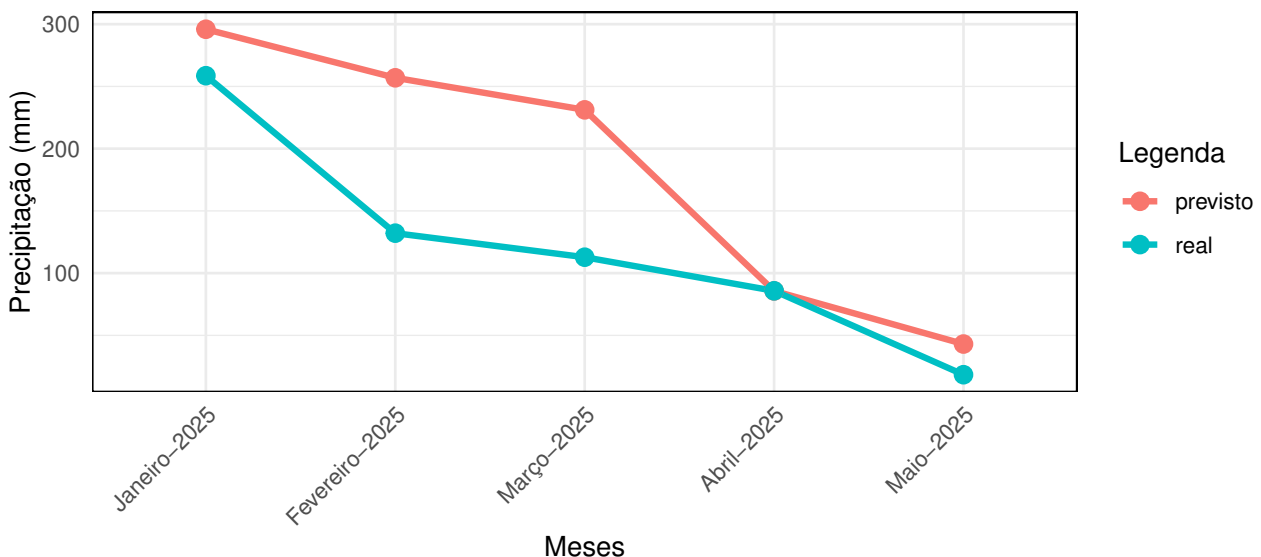


Figura 4.11: Valores previstos x valores reais da variável precipitação da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.

4.2 ANÁLISE DOS MODELOS DE SÉRIES TEMPORAIS — TEMPERATURA MÉDIA MENSAL

Na sequência, apresenta-se a série original da variável temperatura média mensal ($^{\circ}\text{C}$) referente ao período de maio de 2011 a dezembro de 2024 da cidade de Franca-SP (Figura 4.12). Visualmente, é possível intuir a presença da componente sazonalidade e ausência de tendência.




Figura 4.12: Temperatura média mensal, em $^{\circ}\text{C}$, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

Na Figura 4.13 tem-se a FAC da série de temperatura, que apresenta valores significativos nos primeiros lags, indicando dependência temporal. Adicionalmente, observa-se picos sazonais nos múltiplos de 12, evidenciando forte sazonalidade anual característica de séries climatológicas. Já a FACP apresenta um pico significativo no primeiro lag, indicando dependência autorregressiva de primeira ordem, conforme ilustrado na Figura 4.14. Ainda, nota-se que os lags próximos de 12 são significativos, indicando dependência sazonal anual. Esses resultados, combinados com a FAC, sugerem o ajuste dos modelos do tipo SARIMA.

Para a confirmação das componentes presentes na série, foram aplicados os testes de Cox-Stuart para tendência e de Fisher para sazonalidade. O p-valor obtido no teste de Cox-Stuart foi de 0,0747, que por ser maior que 5%, conclui-se que não há evidências estatísticas de tendência na série. Já para o teste de Fisher o p-valor obtido foi $< 0,0001$, muito inferior a 5%, donde conclui-se que a série apresenta sazonalidade. Esses resultados confirmam o que já suspeitávamos com as análises visuais das Figuras 4.12, 4.13 e 4.14.




Figura 4.13: Função de Autocorrelação (FAC) da temperatura.




Figura 4.14: Função de Autocorrelação Parcial (FACP) da temperatura.

Para o ajuste dos modelos, foi utilizada a função *auto.arima*. A partir das sugestões geradas, foram selecionados três modelos cujos parâmetros apresentaram significância estatística, conforme apresentados na Tabela 4.5. Esses modelos foram então avaliados quanto ao desempenho preditivo e à adequação aos dados, considerando critérios de informação.

Tabela 4.5: Estimativas dos parâmetros dos modelos SARIMA ajustados à série de temperatura da cidade de Franca-SP.

Modelo	Parâmetro	Estimativa	Erro padrão	p-valor	AIC	BIC
SARIMA (1,0,1)(0,1,1) ₁₂	ϕ_1	0,85537	0,11953	< 0,00000	453,21	465,41
	θ_1	-0,61508	0,18219	0,00073		
	Θ_1	-0,86820	0,08050	< 0,00000		
SARIMA (1,0,1)(2,1,0) ₁₂	ϕ_1	0,80281	0,18458	< 0,00000	473,80	489,04
	θ_1	-0,27808	0,08689	0,00137		
	Φ_1	-0,562270	0,26769	0,03569		
	Φ_2	-0,74162	0,08323	< 0,00000		
SARIMA (1,0,1)(1,1,1) ₁₂	ϕ_1	0,89120	0,10207	< 0,0001	451,25	466,50
	θ_1	-0,66530	0,16094	< 0,00000		
	Φ_1	-0,20097	0,09700	0,03828		
	Θ_1	-0,78364	0,08014	< 0,00000		

O Modelo 1 se destaca por ser mais simples, com apenas três parâmetros, enquanto os Modelos 2 e 3 possuem quatro. Além disso, seu AIC é muito próximo ao do Modelo 3, indicando desempenho semelhante com menor complexidade. Dessa forma, optou-se pelo Modelo 1 por apresentar um bom equilíbrio entre qualidade de ajuste e simplicidade estrutural. Em seguida, foi realizada a análise dos resíduos desse modelo, a fim de verificar a adequação do ajuste.

Nas Figuras 4.15 e 4.16 apresentam-se a FAC e a FACP dos resíduos, respectivamente. Em ambas, observa-se que não há mais de dois lags significativos, indicando ausência de autocorrelação residual. Para reforçar essa evidência, foi aplicado o teste de Box-Pierce, cujo p-valor (0,9071) não permite rejeitar a hipótese nula de ausência de autocorrelação. Assim, conclui-se que os resíduos apresentam comportamento de ruído branco, evidenciando a adequação do modelo ajustado.




Figura 4.15: Função de Autocorrelação (FAC) dos resíduos da temperatura.




Figura 4.16: Função de Autocorrelação Parcial (FACP) dos resíduos da temperatura.

Para complementar a análise, foi plotado o gráfico Q-Q dos resíduos, exibido na Figura 4.17, confirmando esse comportamento de ruído branco.




Figura 4.17: Resíduos da temperatura.

Na Figura 4.18 são apresentadas as previsões para Temperatura média mensal (em °C) da cidade de Franca-SP. Conforme havíamos analisado anteriormente, a série apresenta um comportamento claramente sazonal, com oscilações regulares ao longo dos anos. A previsão obtida pelo modelo indica a manutenção desse padrão, com uma leve queda da temperatura no curto prazo. Portanto, o modelo ajustado obteve um desempenho excelente para temperatura.




Figura 4.18: Previsão para temperatura média mensal, em °C, da cidade de Franca-SP, compreendida entre os meses de Janeiro a Maio de 2025.

As previsões do modelo SARIMA $(1,0,1)(0,1,1)$ para a série de temperatura de Franca-SP, entre janeiro a maio de 2025, indicam um bom desempenho preditivo, visto que os erros observados foram baixos e os valores reais permaneceram dentro dos intervalos de confiança estimados, conforme pode ser observado na Tabela 4.6. Além disso, o modelo reproduziu o

comportamento sazonal da série, com temperaturas mais elevadas nos primeiros meses do ano e redução gradual ao longo do período analisado, evidenciando sua adequação para previsões de curto prazo.

Tabela 4.6: Previsão do Modelo 1 - SARIMA (1,0,1)(0,1,1) para a série de temperatura da cidade de Franca-SP.

Mês	Valor Previsto	Valor Real	Erro	Limite Inferior IC 95%	Limite Superior IC 95%
Jan/2025	23,5	23,3	-0,2	21,6	25,4
Fev/2025	23,3	24,3	1	21,4	25,3
Mar/2025	23,3	24,1	0,8	21,3	25,2
Abr/2025	22,2	21,8	-0,4	20,2	24,2
Mai/2025	20,3	19,9	-0,4	18,2	22,3

Na Tabela 4.7, o RMSE está muito próximo de 0, e isso indica que o modelo erra por cerca de $0,921^{\circ}\text{C}$ (aproximadamente 1°C), assim como o MAE indicando que o modelo erra em média por $0,7^{\circ}\text{C}$. Esses resultados estão em consonância com os encontrados por BORGES et al. (2025) [4]. O ME mostra um leve viés de subestimação, ou seja, o modelo tende a prever (em média) a temperatura um pouco mais baixa do que o valor real. Já o MASE (0,577) diz que o modelo é superior ao modelo ingênuo (Naive). Isso significa dizer que o modelo é aproximadamente 42% melhor do que simplesmente dizer que “a temperatura de amanhã será igual a hoje”. Na Figura 4.19 é realizada a comparação entre os valores previstos e observados, confirmando também a boa aderência do modelo.

Tabela 4.7: Métricas do Modelo 1 - SARIMA (1,0,1)(0,1,1) para a série de temperatura da cidade de Franca-SP.

RMSE	MAE	ME	MASE
0,921	0,714	0,127	0,577

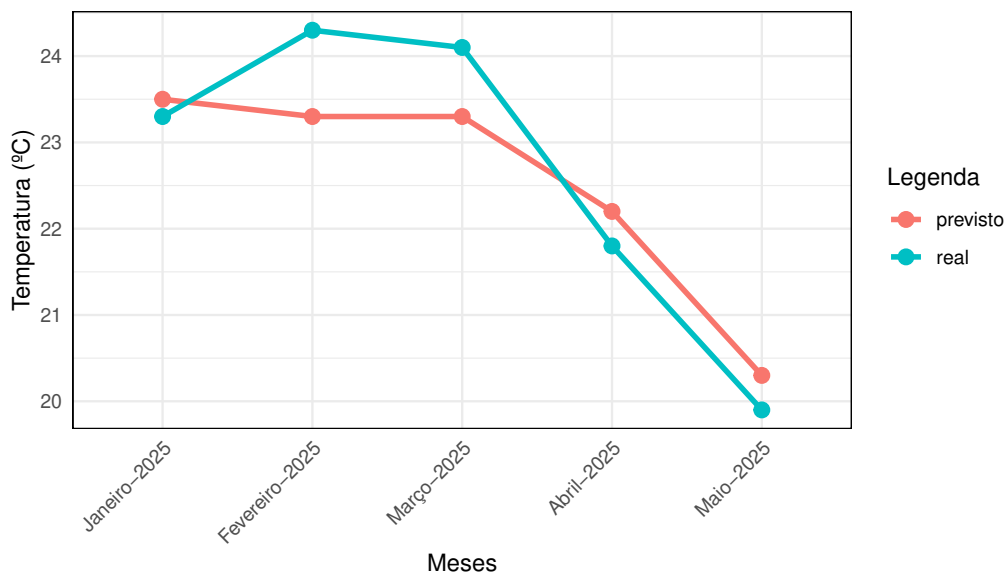


Figura 4.19: Valores previstos x valores reais da variável temperatura da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.

4.3 ANÁLISE DOS MODELOS DE SÉRIES TEMPORAIS — UMIDADE RELATIVA DO AR

Na sequência, é apresentada a série histórica da variável umidade relativa do ar (%) para o período de maio de 2011 a dezembro de 2024, referente ao município de Franca (Figura 4.20). Observa-se que a série não apresenta tendência definida ao longo do tempo, mantendo-se relativamente estável em torno de uma média, porém evidencia um comportamento sazonal bem caracterizado, com variações recorrentes ao longo dos anos. Nota-se a ocorrência de períodos com valores mais elevados de umidade, intercalados com fases de redução mais acentuada, o que reflete a influência das condições climáticas típicas da região, especialmente a alternância entre estações mais úmidas e mais secas.




Figura 4.20: Umidade relativa do ar, em %, da cidade de Franca-SP, compreendida entre os anos de 2011 a 2024.

A FAC da série de umidade apresenta valores estatisticamente significativos, conforme ilustrado na Figura 4.21, evidenciando a existência de dependência temporal. Observam-se, ainda, picos significativos nos lags múltiplos de 12, o que caracteriza um padrão sazonal anual típico de séries climáticas. Por sua vez, a FACP revela um pico significativo no primeiro lag, conforme apresentado na Figura 4.22, sugerindo a presença de um componente autorregressivo de primeira ordem. Além disso, verificam-se valores significativos em lags próximos a 12, reforçando a existência de dependência sazonal anual.

Em conjunto, os resultados obtidos por meio da FAC e da FACP indicam que modelos do tipo SARIMA constituem uma abordagem adequada para a modelagem da série.




Figura 4.21: Função de Autocorrelação (FAC) da umidade.




Figura 4.22: Função de Autocorrelação Parcial (FACP) da umidade.

O teste de Cox-Stuart foi aplicado para verificar a presença de tendência na série. O p-valor obtido no teste foi de 0,0784. Por ser superior ao nível de significância de 5%, conclui-se que não há evidências estatísticas suficientes para afirmar a existência de tendência na série analisada.

Isso sugere que, ao longo do período considerado, a série não apresenta um comportamento sistemático de crescimento ou decrescimento.

Além disso, foi realizado o teste de Fisher com o objetivo de investigar a presença de sazonalidade. Como o p-valor obtido foi inferior a 0,0001, ou seja, muito menor que o nível de significância adotado, há fortes evidências estatísticas de que a série apresenta um componente sazonal significativo. Esse resultado indica a existência de padrões periódicos que se repetem ao longo do tempo.

Para o ajuste do modelo, foi utilizada a função *auto.arima*, que fornece sugestões de modelos com base em critérios de informação. A partir dessas sugestões, alguns modelos considerados adequados foram selecionados e avaliados comparativamente, conforme apresentado na Tabela 4.8. Essa etapa permitiu identificar o modelo que melhor descreve a dinâmica da série, considerando tanto a qualidade do ajuste quanto o número de parâmetros.

Tabela 4.8: Estimativas dos parâmetros dos modelos SARIMA ajustados à série de umidade.

Modelo	Parâmetro	Estimativa	Erro padrão	p-valor	AIC	BIC
SARIMA (1,0,0)(1,1,0) ₁₂	ϕ_1	0,24251	0,07829	0,00195	1033,51	1042,66
	Φ_1	-0,47760	0,07318	< 0,00000		
SARIMA (0,0,1)(0,1,1) ₁₂	θ_1	0,18419	0,07082	0,00929	1009,15	1018,30
	Θ_1	-0,76491	0,06781	< 0,00000		
SARIMA (0,0,1)(1,1,0) ₁₂	θ_1	0,20835	0,07209	0,00385	1034,91	1044,06
	Φ_1	-0,48087	0,07302	< 0,00000		

Todos os modelos indicaram parâmetros significativos. O modelo 2 foi o que se destacou entre todos, uma vez que possui o menor valor de AIC e BIC. A seguir serão exibidas as análises dos resíduos.

Nas Figuras 4.23 e 4.24 são apresentadas, respectivamente, a FAC e a FACP dos resíduos. Em ambas, observam-se no máximo dois lags significativos, o que indica ausência de autocorrelação residual.

Para confirmar essa evidência, foi aplicado o teste de Box-Pierce, que resultou em p-valor igual a 0,9071. Assim, não se rejeita a hipótese nula de inexistência de autocorrelação, indicando que os resíduos apresentam comportamento compatível com ruído branco.




Figura 4.23: Função de Autocorrelação (FAC) dos resíduos da umidade.




Figura 4.24: Função de Autocorrelação Parcial (FACP) dos resíduos da umidade.

Com o objetivo de complementar a análise, apresenta-se o gráfico Q-Q dos resíduos, mostrado na Figura 4.25, evidenciando o comportamento característico de ruído branco.

Na Figura 4.26 são apresentadas as previsões da umidade relativa do ar (em %) para a cidade de Franca-SP, referentes ao período de janeiro a maio de 2025. Observa-se a presença de um padrão sazonal bem definido, com valores previstos mais elevados nos primeiros meses do ano, seguidos de um decaimento gradual ao longo do período analisado. Esse comportamento é




Figura 4.25: Resíduos da unidade.

coerente com a dinâmica climática regional, na qual os meses iniciais do ano tendem a apresentar maior umidade, com redução progressiva à medida que se aproxima o período mais seco.

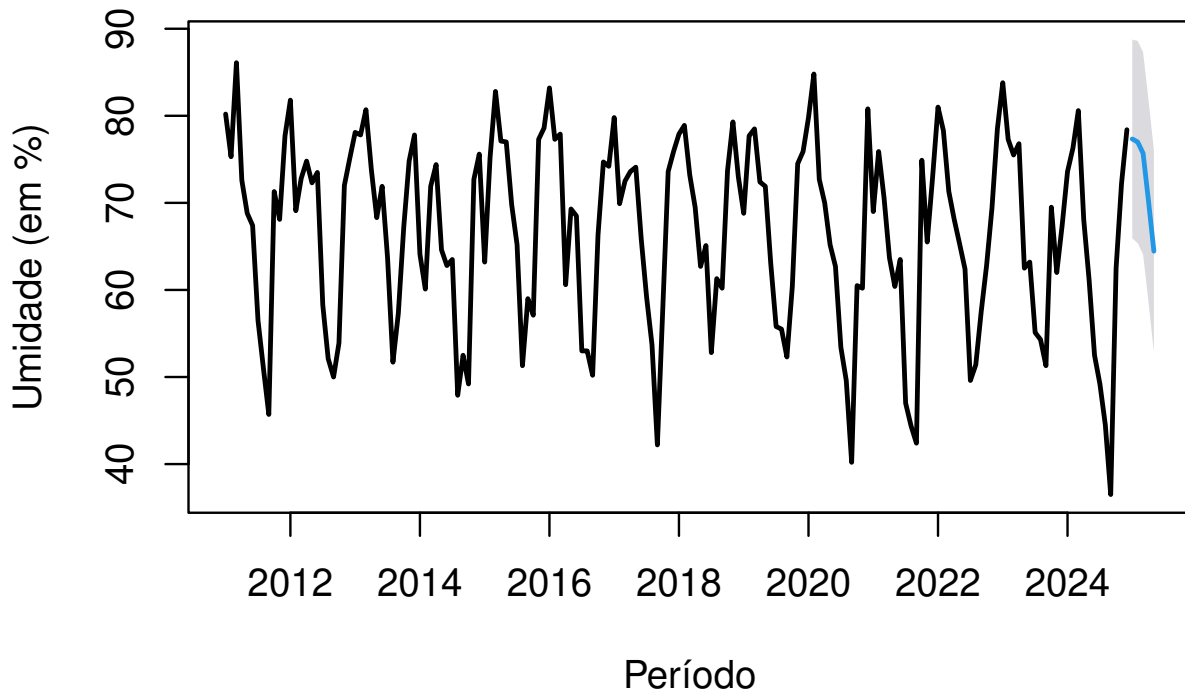


Figura 4.26: Previsão para umidade relativa do ar, em %, compreendida entre os meses de Janeiro a Maio de 2025.

De modo geral, observa-se na tabela 4.9 uma boa aderência do modelo SARIMA $(0,0,1)(0,1,1)$ aos valores reais de umidade relativa do ar da cidade de Franca-SP no período analisado. As previsões acompanharam de forma satisfatória o comportamento observado da série, apresentando diferenças moderadas na maioria dos meses.

Tabela 4.9: Previsão do Modelo 2 - SARIMA $(0,0,1)(0,1,1)$ para a série de umidade da cidade de Franca-SP.

Mês	Valor Previsto	Valor Real	Erro	Limite Inferior IC 95%	Limite Superior IC 95%
Jan/2025	77,3	77,7	0,4	65,9	88,7
Fev/2025	77	68,7	-8,3	65,3	88,6
Mar/2025	75,7	69,1	-6,6	64	87,3
Abr/2025	70,2	78,6	8,4	58,6	81,8
Mai/2025	64,4	68	3,6	52,8	76

Na tabela 4.10, o valor relativamente baixo do RMSE indica um erro em torno de 5,614% (na unidade da umidade), enquanto o MAE aponta um erro médio de aproximadamente 4,205%. O ME evidencia um leve viés de superestimação, sugerindo que o modelo tende a prever valores de umidade um pouco maiores do que os valores reais. Por fim, o MASE igual a 0,6 indica que

o modelo supera o desempenho do modelo ingênuo (Naive), sendo cerca de 40% mais eficiente do que a simples suposição de que “a umidade de amanhã será igual à de hoje”.

Nota-se maior discrepância em fevereiro, março e abril, conforme exibido na Figura 4.27, porém todos os valores reais permaneceram dentro dos respectivos intervalos de confiança estimados pelo modelo, o que reforça a consistência das previsões.

Tabela 4.10: Métricas do Modelo 2 - SARIMA (0,0,1)(0,1,1) para a série de umidade da cidade de Franca-SP.

RMSE	MAE	ME	MASE
5,614	4,205	-0,665	0,600

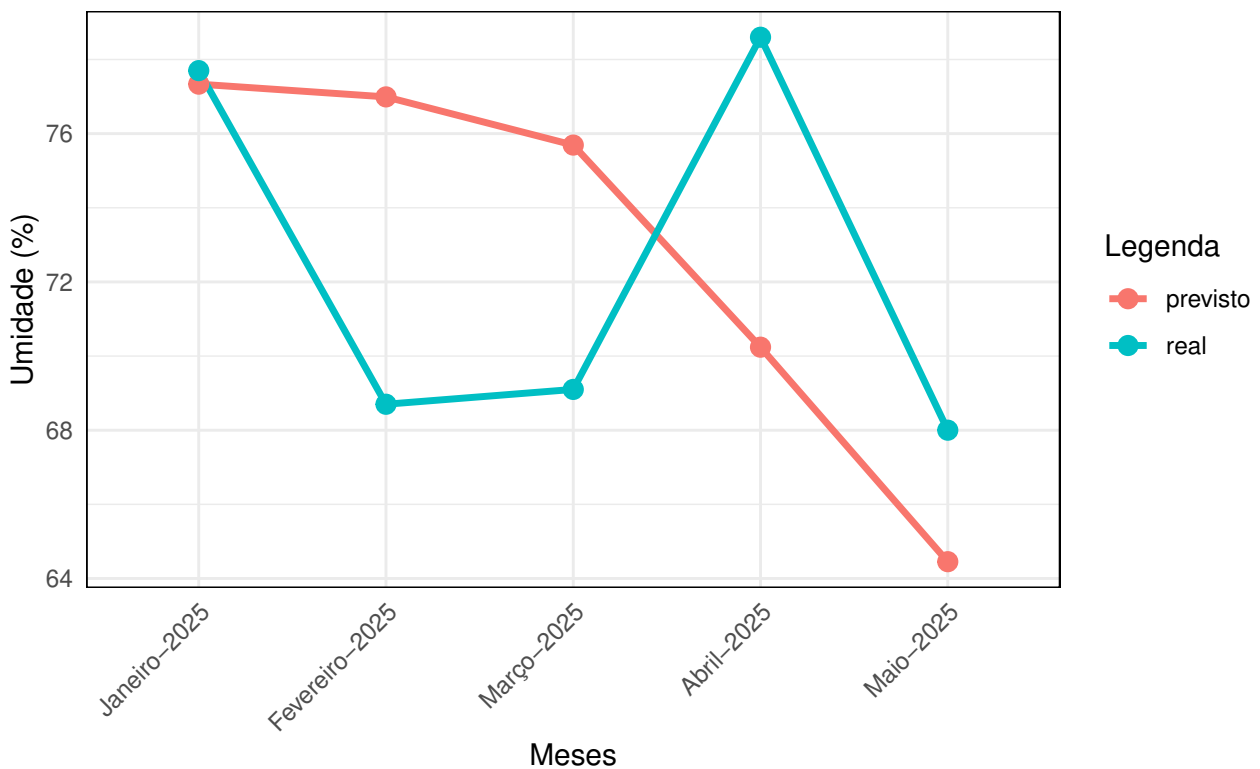


Figura 4.27: Valores previstos x valores reais da variável umidade da cidade de Franca-SP, entre os meses de janeiro a maio de 2025.

5. CONCLUSÕES

Com base nos resultados obtidos, observa-se que os modelos SARIMA ajustados apresentaram desempenhos distintos para cada variável climática analisada.

Para a série de precipitação total mensal, o modelo SARIMA $(0,0,1)(0,1,1)_{12}$ apresentou um desempenho razoável. As métricas de erro, como RMSE e MAE, indicaram valores relativamente elevados quando comparados às demais variáveis analisadas. Esse comportamento pode estar relacionado à alta variabilidade característica da precipitação, que tende a apresentar flutuações mais intensas ao longo do tempo, dificultando sua modelagem e previsão. Ainda assim, destaca-se que no mês de abril a previsão ficou bem próxima do valor observado.

Em relação à temperatura média mensal, o modelo SARIMA $(1,0,1)(0,1,1)_{12}$ demonstrou o melhor desempenho entre as variáveis analisadas. As previsões obtidas apresentaram erros inferiores a 1°C , indicando alta precisão do modelo. Além disso, as métricas de desempenho, como RMSE, MAE, ME e MASE, apresentaram valores baixos, evidenciando que a série de temperatura foi bem captada pelo modelo de previsão.

Para a variável umidade relativa do ar, o modelo SARIMA $(0,0,1)(0,1,1)_{12}$ também apresentou resultados satisfatórios. Embora o desempenho não tenha sido tão preciso quanto o verificado para a temperatura, os valores das métricas de erro permaneceram relativamente baixos, indicando boa capacidade preditiva. Destaca-se que o mês de janeiro de 2025 apresentou a previsão mais próxima do valor observado.

De modo geral, os resultados obtidos demonstram que modelos da família SARIMA podem ser ferramentas úteis para a previsão de variáveis climáticas. No contexto da cidade de Franca-SP, importante região produtora de café no Brasil, previsões confiáveis de precipitação, temperatura e umidade relativa do ar podem auxiliar produtores rurais na tomada de decisões relacionadas ao manejo da cultura, como planejamento da irrigação, períodos de plantio e colheita, além do monitoramento de condições climáticas que podem impactar diretamente a produtividade das lavouras.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AKAIKE, H.: *A new look at the statistical model identification*. IEEE Transactions on Automatic Control, 19(6):716–723, 1974. <https://doi.org/10.1109/TAC.1974.1100705>.
- [2] ALBURQUEQUE, R. C. d.: *Modelagem de séries temporais: aplicação em dados de precipitação na região do sertão de Pernambuco, Brasil*. Em *Dissertação em Biometria e Estatística Aplicada - Universidade Federal Rural de Pernambuco*, p. 27, 2019.
- [3] BARBOSA, E. C., SILVA, C. H. O., NASCIMENTO, M. e LIMA, J. E. d.: *Análise e previsão de temperatura máxima mensal da cidade do Rio de Janeiro (RJ) para o ano de 2016*. Em *Revista Brasileira de Biometria*, pp. 174–193, 2017. <https://biometria.ufla.br/index.php/BBJ/article/view/84>.
- [4] BORGES, P. d. F., PEREIRA, W. E., MELO JÚNIOR, J. J. B. d., SILVA, A. T. d. S., ARAÚJO, L. d. S., SILVA, T. E. S. d. e MACEDO, P. d. A.: *Análise de séries temporais de precipitação e temperatura no município de Areia-PB utilizando modelos estatísticos ARIMA e ETS*. Em *Caminhos de Geografia*, vol. 26, pp. 91–110, 2025.
- [5] BOX, G. E. P. ; PIERCE, D. A.: *Distribution of residual autocorrelations in autoregressive-integrated moving average time series models, Washington*. Em *Journal of the American Statistical Association*, pp. 1509–1526, v. 65, n. 332, 1970.
- [6] BOX, G. E. P.; JENKINS, G. M. R. G. C. L. G. M.: *Time Series Analysis: Forecasting and Control*, vol. 1. Wiley, 5ª ed., 2015.
- [7] CARVALHO, C. H. S.: *Cultivares de café: origem, características e recomendações*. Embrapa Café, 2008.
- [8] CHECHI, L.; BAYER, F. M.: *Modelos univariados de séries temporais para previsão das temperaturas médias mensais de Erechim, RS*. Em *Revista Brasileira de Engenharia Agrícola e Ambiental*, 2012. http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662012001200009.
- [9] CINTRA, R. A., MELO, M. I. P. e FILHO, J. S. S.: *Modelos de séries temporais para a previsão da temperatura média mensal de Lavras, MG*. Em *Sigmae*, pp. 596–605, 2019. <https://publicacoes.unifal-mg.edu.br/revistas/index.php/sigmae/article/view/1049>.

- [10] CONAB: *Acompanhamento da Safra Brasileira de Café*, 2022. <https://www.conab.gov.br/info-agro/safras/cafe>, acessado em 07/03/2026.
- [11] COX, D. R.; STUART, A.: *Some quick tests for trend in location and dispersion*. Em *Biometrika*, pp. 80–95, v. 42, n. 1/2, 1955.
- [12] ENDERS, W.: *Applied Econometric Time Series*. Wiley, 4^a ed., 2014.
- [13] GUJARATI, D. N.; PORTER, D. C.: *Econometria básica*. AMGH, 2011.
- [14] HAMILTON, J. D.: *Time Series Analysis*. Princeton: Princeton University Press, 1994.
- [15] HYNDMAN, R. J.; KOEHLER, A. B.: *Another look at measures of forecast accuracy*. *International Journal of Forecasting*, 22(4):679–688, 2006. <http://dx.doi.org/10.1016/j.ijforecast.2006.03.001>.
- [16] HYNDMAN, R. J.; ATHANASOPOULOS, G.: *Forecasting: principles and practice*, vol. 1. OTexts, 3^a ed., 2021.
- [17] IHAKA, R. e GENTLEMAN, R.: *The R Project for Statistical Computing*, 1993. <https://www.r-project.org/>, acessado em 07/03/2026.
- [18] IPCC: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, 2021. <https://www.ipcc.ch/report/ar6/wg1/>, Acesso em: 07 mar. 2026.
- [19] KÖPPEN: *Classificação climática de Köppen para os municípios brasileiros*. <https://koppenbrasil.github.io/>, acessado em 07/03/2026.
- [20] LATORRE, M.do R. D. de. O.; CARDOSO, M.R.A.: *Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos*. Em *Revista Brasileira de Epidemiologia*, pp. 145–152, v. 4, 2001.
- [21] MORETTIN, P. A. e TOLOI, C. M. C.: *Análise de séries temporais*. Blucher, 2^a ed, 2006.
- [22] NIELSEN, A.: *Análise prática de séries temporais: predição com estatística e aprendizado de máquina*. Alta Books, 1^a ed., 2021.
- [23] PRIESTLEY, M. B.: *Spectral analysis and time series*. Academic Press, 1^a ed., 1989.
- [24] SCHWARZ, G. E.: *Estimating the dimension of a model*. Em *The Annals of Statistics*, *Hayward*, pp. 461–464, v. 6, n. 2, 1978.