



VICTÓRIA BARBOSA TAVARES

**ANÁLISE DA BASE DOS PREÇOS DE MILHO PARA AS
PRINCIPAIS PRAÇAS DE NEGOCIAÇÃO EM MINAS GERAIS
POR MODELOS DE SÉRIES TEMPORAIS**

LAVRAS – MG

2025

VICTÓRIA BARBOSA TAVARES

**ANÁLISE DA BASE DOS PREÇOS DE MILHO PARA AS PRINCIPAIS PRAÇAS DE
NEGOCIAÇÃO EM MINAS GERAIS POR MODELOS DE SÉRIES TEMPORAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

Profa. Dra. Izabela Regina Cardoso de Oliveira
Orientadora

Prof. Dr. Sérgio Domingos Simão
Coorientador

**LAVRAS – MG
2025**

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Tavares, Victória Barbosa.

Análise da base dos preços de milho para as principais praças de negociação em Minas Gerais por modelos de séries temporais / Victória Barbosa Tavares. - 2025.
82 p. : il.

Orientadora: Izabela Regina Cardoso de Oliveira

Coorientador: Sérgio Domingos Simões

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.

Bibliografia.

1. Commodities. 2. Modelo AR. 3. Modelo Garch. 4. Mercado de derivativos. I. Oliveira, Izabela Regina Cardoso de. II. Simões, Sérgio Domingos. III. Universidade Federal de Lavras. IV. Título.

VICTÓRIA BARBOSA TAVARES

**ANÁLISE DA BASE DOS PREÇOS DE MILHO PARA AS PRINCIPAIS PRAÇAS DE
NEGOCIAÇÃO EM MINAS GERAIS POR MODELOS DE SÉRIES TEMPORAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

APROVADA em 29 de agosto de 2025.

Profa. Dra. Leticia Lima Milani Rodrigues UNIFAL

Prof. Dr. Ednilson Sebastião de Ávila UFLA

Prof. Dr. Paulo Henrique Sales Guimarães UFLA

Profa. Dra. Izabela Regina Cardoso de Oliveira
Orientadora

Prof. Dr. Sérgio Domingos Simão
Co-Orientador

**LAVRAS – MG
2025**

Dedico este trabalho à criança que fui, que sonhava alto sem imaginar até onde poderia chegar. Que nunca perdeu a curiosidade, acreditou no próprio potencial e me trouxe até aqui.

AGRADECIMENTOS

A Deus, pela força, proteção e sabedoria concedidas ao longo de toda esta caminhada.

À minha orientadora, Profa. Dra. Izabela Regina Cardoso de Oliveira, pela dedicação, paciência, confiança e por todo o conhecimento compartilhado, que foram fundamentais para o desenvolvimento deste trabalho.

Ao Sérgio Simões, pelo apoio técnico, pela disponibilidade e pela contribuição decisiva nas análises e interpretações.

À minha família, pelo incentivo constante, pela compreensão nos momentos de ausência e pelo amor incondicional que me fortaleceu nos dias mais difíceis.

Aos amigos e colegas de curso, pelo companheirismo, pelas conversas motivadoras e pelo auxílio durante o percurso acadêmico.

À Universidade Federal de Lavras, aos professores e funcionários do Programa de Pós-Graduação em Estatística e Experimentação Agropecuária, pelo suporte e pela oportunidade de aprendizado.

Agradece, de forma especial, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro concedido por meio da bolsa de estudos, fundamental para a viabilização desta pesquisa.

Por fim, a todos que, de alguma forma, contribuíram para a realização deste trabalho, o meu sincero agradecimento.

“O sucesso é ir de fracasso em fracasso sem perder entusiasmo.”

(Winston Churchill)

RESUMO

O Brasil vem se tornando um dos principais países produtores e exportadores de milho, sendo uma das atividades econômicas mais relevantes exercidas no setor agropecuário nacional. O milho é um cereal de alto valor nutricional, amplamente utilizado como matéria-prima em diversos segmentos da indústria, como o setor alimentício, a produção agropecuária e até mesmo na fabricação de combustíveis renováveis, como o etanol. Conhecer como o preço dessa *commodity* se comporta é fundamental para a negociação dessa mercadoria, pois possibilita a maximização de receitas e a redução de riscos tanto para compradores quanto para vendedores. No mercado de derivativos, a base ou “*basis*” refere-se à diferença entre o preço da *commodity* no mercado físico e o seu preço no mercado futuro. O enfraquecimento ou fortalecimento dessa base pode indicar cenários mais ou menos favoráveis à trajetória dos preços do produto. Diante disso, este trabalho tem como objetivo ajustar modelos de séries temporais para análise da volatilidade da base de preços do milho no estado de Minas Gerais, comparando essa variação nos diferentes mercados físicos dessa região. Foram utilizados o modelo Autorregressivo (AR) e o modelo de Heteroscedasticidade Condicional Auto Regressiva Generalizada (GARCH). Os dados utilizados correspondem aos preços diários do milho em mercados físicos de diferentes praças mineiras, bem como às cotações do mercado futuro obtidas na B3, abrangendo o período de 16/07/2018 a 31/12/2024. Os modelos ajustados apresentaram bom desempenho, permitindo a realização de previsões para um período de 7 e 15 dias em cada praça analisada, a modelagem mostrou que a base do milho em Minas Gerais tem volatilidade persistente, com choques que se estendem por vários períodos, permitindo prever melhor as variações e apoiar decisões mais seguras de comercialização. Com base nos critérios de avaliação aplicados, concluiu-se que os modelos foram adequados, ajustando-se bem aos dados de base diários da *commodity* milho nos mercados do estado de Minas Gerais, no período estudado.

Palavras-chave: *Commodities*; Modelo AR; Modelo Garch; Mercado de derivativos.

ABSTRACT

Brazil has become one of the leading producers and exporters of corn, which is one of the most important economic activities in the national agricultural sector. Corn is a cereal with high nutritional value, widely used as a raw material in various industry segments, such as the food sector, agricultural production, and even in the manufacture of renewable fuels, such as ethanol. Understanding how the price of this commodity behaves is essential for trading this commodity, as it enables the maximization of revenues and the reduction of risks for both buyers and sellers. In the derivatives market, the basis refers to the difference between the price of the commodity in the physical market and its price in the futures market. The weakening or strengthening of this basis may indicate scenarios that are more or less favorable to the trajectory of the product's prices. The weakening or strengthening of this basis may indicate scenarios that are more or less favorable to the product's price trajectory. Given this, this study aims to adjust time series models to analyze the volatility of the corn price basis in the state of Minas Gerais, comparing this variation in the different physical markets in this region. The Autoregressive (AR) model and the Generalized Autoregressive Conditional Heteroscedasticity (GARCH) model were used. The data used corresponds to the daily prices of corn in physical markets in different locations in Minas Gerais, as well as futures market prices obtained from B3, covering the period from July 16, 2018, to December 31, 2024. The adjusted models performed well, allowing predictions to be made for a period of 7 and 15 days in each market analyzed. The modeling showed that the corn base in Minas Gerais has persistent volatility, with shocks extending over several periods, allowing for better prediction of variations and supporting more secure marketing decisions. Based on the evaluation criteria applied, it was concluded that the models were adequate, adjusting well to the daily base data for corn in the markets of the state of Minas Gerais during the period studied.

Keywords: Commodities; AR model; Garch model; Derivatives market.

INDICADORES DE IMPACTO

Este estudo tem como objetivo analisar o comportamento e a volatilidade da base de preços do milho no Estado de Minas Gerais por meio da aplicação de modelos de séries temporais AR e GARCH, oferecendo impactos relevantes de natureza econômica, tecnológica e social. Os resultados obtidos permitem caracterizar padrões de dinâmica da base e identificar períodos de maior instabilidade de preços, fornecendo subsídios quantitativos para a tomada de decisão de produtores rurais, cooperativas agropecuárias, indústrias de processamento e agentes atuantes no mercado futuro. Do ponto de vista econômico, o trabalho apresenta potencial para reduzir riscos associados à comercialização do milho, contribuindo para a minimização de perdas financeiras, otimização da gestão de estoques e melhoria da eficiência nas estratégias de hedge e negociação, especialmente em regiões produtoras do território mineiro, como o Noroeste e o Triângulo Mineiro. No âmbito tecnológico, a pesquisa promove a difusão e a aplicação de ferramentas estatísticas avançadas de modelagem de séries temporais no agronegócio, fortalecendo a capacidade analítica do setor e incentivando o uso de métodos quantitativos no planejamento produtivo e comercial. Sob a perspectiva social, ao contribuir para a estabilidade da renda agrícola e para a redução da incerteza enfrentada pelos produtores, o estudo impacta indiretamente a segurança econômica de famílias rurais e a sustentabilidade das cadeias produtivas locais. Os impactos apresentados são predominantemente potenciais, com possibilidade de aplicação direta dos resultados por agentes do mercado e instituições de apoio ao produtor, caracterizando também um viés extensionista ao gerar conhecimento aplicável à sociedade externa à UFLA, especialmente produtores e cooperativas do setor agrícola. O trabalho se enquadra principalmente nas áreas temáticas de Tecnologia e Produção e Trabalho, conforme a Política Nacional de Extensão, e apresenta alinhamento com os Objetivos de Desenvolvimento Sustentável da ONU, em especial o ODS 2 (Fome Zero e Agricultura Sustentável), o ODS 8 (Trabalho Decente e Crescimento Econômico) e o ODS 12 (Consumo e Produção Responsáveis), ao contribuir para uma agricultura mais eficiente, resiliente e economicamente sustentável no contexto da agenda 2030.

IMPACT INDICATORS

This study aims to analyze the behavior and volatility of the corn price base in the state of Minas Gerais through the application of AR and GARCH time series models, offering relevant economic, technological, and social impacts. The results obtained allow us to characterize patterns of base dynamics and identify periods of greater price instability, providing quantitative support for decision-making by rural producers, agricultural cooperatives, processing industries, and agents operating in the futures market. From an economic standpoint, the work has the potential to reduce risks associated with corn sales, contributing to the minimization of financial losses, optimization of inventory management, and improvement of efficiency in hedging and trading strategies, especially in producing regions of Minas Gerais, such as the Northwest and the Triângulo Mineiro. In the technological sphere, the research promotes the dissemination and application of advanced statistical tools for time series modeling in agribusiness, strengthening the sector's analytical capacity and encouraging the use of quantitative methods in production and commercial planning. From a social perspective, by contributing to the stability of agricultural income and reducing the uncertainty faced by producers, the study indirectly impacts the economic security of rural families and the sustainability of local production chains. The impacts presented are predominantly potential, with the possibility of direct application of the results by market agents and producer support institutions, also characterizing an extensionist bias by generating knowledge applicable to society outside UFLA, especially producers and cooperatives in the agricultural sector. The work falls mainly within the thematic areas of Technology and Production and Labor, in accordance with the National Extension Policy, and is aligned with the UN Sustainable Development Goals, in particular SDG 2 (Zero Hunger and Sustainable Agriculture), SDG 8 (Decent Work and Economic Growth), and SDG 12 (Responsible Consumption and Production), by contributing to more efficient, resilient, and economically sustainable agriculture in the context of the 2030 agenda.

LISTA DE FIGURAS

Figura 2.1 – Mapa do Valor da Produção de Milho em Grão no Brasil 2022 (Mil Reais). . .	18
Figura 2.2 – Mapa do Valor da Produção do Leite no Brasil 2022 (Mil Reais).	20
Figura 2.3 – Ranking do Valor da Produção das culturas de Minas Gerais 2022 (Mil Reais).	21
Figura 2.4 – Mapa do Valor da Produção do milho em Minas Gerais 2022 (Mil Reais). . .	21
Figura 3.1 – Distribuição das praças de comércio de milho pelo Estado de Minas Gerais.	39
Figura 4.1 – Série histórica dos preços de milho nas praças físicas de Minas Gerais acompanhados da Série Histórica da B3.	44
Figura 4.2 – Base de Milho para as principais praças de comercialização de MG para o período de julho de 2018 a dezembro de 2024.	46
Figura 4.3 – Predição 7 dias – Iraí de Minas	52
Figura 4.4 – Predição 15 dias – Iraí de Minas	52
Figura 4.5 – Predição 7 dias – Noroeste de Minas	53
Figura 4.6 – Predição 15 dias – Noroeste de Minas	53
Figura 4.7 – Predição 7 dias – Oeste de Minas	53
Figura 4.8 – Predição 15 dias – Oeste de Minas	53
Figura 4.9 – Predição 7 dias – Sudoeste de Minas	53
Figura 4.10 – Predição 15 dias – Sudoeste de Minas	53
Figura 4.11 – Predição 7 dias – Triângulo Mineiro	54
Figura 4.12 – Predição 15 dias – Triângulo Mineiro	54
Figura 4.13 – Predição 7 dias – Unaí	54
Figura 4.14 – Predição 15 dias – Unaí	54
Figura 4.15 – Desvio Padrão Condicional do modelo GARCH da praça de Iraí	56
Figura 4.16 – Desvio Padrão Condicional do modelo GARCH da praça de Noroeste	56
Figura 4.17 – Desvio Padrão Condicional do modelo GARCH da praça de Oeste	56
Figura 4.18 – Desvio Padrão Condicional do modelo GARCH da praça de Sudoeste	56
Figura 4.19 – Desvio Padrão Condicional do modelo GARCH da praça de Triângulo Mineiro	56
Figura 4.20 – Desvio Padrão Condicional do modelo GARCH da praça de Unaí	56
Figura 4.21 – Volatilidade Condicional do modelo GARCH da praça de Iraí	57
Figura 4.22 – Volatilidade Condicional do modelo GARCH da praça do Noroeste	57

Figura 4.23 – Volatilidade Condicional do modelo GARCH da praça de Oeste	58
Figura 4.24 – Volatilidade Condicional do modelo GARCH da praça de Sudoeste	58
Figura 4.25 – Volatilidade Condicional do modelo GARCH da praça do Triângulo Mineiro	58
Figura 4.26 – Volatilidade Condicional do modelo GARCH da praça de Unaí	58
Figura 1 – Serie histórica da base de milho de Iraí de Minas.	65
Figura 2 – ACF e PACF da base de Iraí.	66
Figura 3 – ACF e PACF dos resíduos do Modelo AR para a base de Iraí.	66
Figura 4 – QQ-Plot dos Resíduos Padronizados da base de Iraí.	67
Figura 5 – Serie histórica da base de milho do Noroeste de Minas.	68
Figura 6 – ACF e PACF da base do Noroeste.	68
Figura 7 – ACF e PACF dos resíduos do Modelo AR para a base do Noroeste.	69
Figura 8 – QQ-Plot dos Resíduos Padronizados da base do Noroeste.	69
Figura 9 – Serie histórica da base de milho do Oeste de Minas.	70
Figura 10 – ACF e PACF da base do Oeste de Minas.	71
Figura 11 – ACF e PACF dos resíduos do Modelo AR para a base do Oeste de Minas. . .	71
Figura 12 – QQ-Plot dos Resíduos Padronizados da base do Oeste de Minas.	72
Figura 13 – Serie histórica da base de milho do Sudoeste de Minas.	73
Figura 14 – ACF e PACF da base do Sudoeste Mineiro.	73
Figura 15 – ACF e PACF dos resíduos do Modelo AR para a base do Sudoeste Mineiro. .	74
Figura 16 – QQ-Plot dos Resíduos Padronizados da base do Sudoeste Mineiro.	75
Figura 17 – Serie histórica da base de milho do Triângulo Mineiro.	76
Figura 18 – ACF e PACF da base do Triângulo Mineiro.	76
Figura 19 – ACF e PACF dos resíduos do Modelo AR para a base do Triângulo Mineiro.	77
Figura 20 – QQ-Plot dos Resíduos Padronizados da base do Triângulo Mineiro.	77
Figura 21 – Serie histórica da base de milho do Triângulo Mineiro.	78
Figura 22 – ACF e PACF da base de Unaí	79
Figura 23 – ACF e PACF dos resíduos do Modelo AR para a base de Unaí.	79
Figura 24 – QQ-Plot dos Resíduos Padronizados da base de Unaí.	80

LISTA DE TABELAS

Tabela 4.1 – Estatísticas descritivas das praças de comércio de milho de Minas Gerais.	47
Tabela 4.2 – Estatísticas dos Testes de Raiz Unitária.	48
Tabela 4.3 – Modelos AR selecionados e resultados do Teste de Ljung-Box para os resíduos (valores p).	49
Tabela 4.4 – Teste ARCH LM.	50
Tabela 4.5 – Parâmetros Estimados do Modelo GARCH considerando as diferentes praças físicas de Minas Gerais.	51
Tabela 4.6 – Parâmetros de Predição.	55

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	15
2	REFERENCIAL TEÓRICO	17
2.1	Produção nacional de milho e sua importância econômica	17
2.2	Mercados e Agentes	22
2.2.1	A base	26
2.3	Modelos de Séries Temporais para análise de preços	28
2.3.1	O modelo AR e o modelo MA	30
2.3.2	O modelo ARMA e o modelo ARIMA	31
2.3.3	O modelo ARCH e o modelo GARCH	34
2.3.4	Modelos de Séries Temporais na previsão de preços e de bases de <i>commodities</i> agrícolas	35
3	Metodologia	38
3.1	O conjunto de dados	38
3.2	Análise e Ajuste dos Modelos para as Bases	39
3.2.1	Recursos Computacionais Utilizados	41
4	Análise dos Resultados	43
4.1	Análise exploratória dos dados	43
4.2	O Modelo AR	49
4.3	O Modelo GARCH	50
4.4	Os modelos preditivos para as bases de preços nas principais praças de Minas Gerais	52
5	Considerações Finais	60
	REFERÊNCIAS	62
	ANEXOS	65

1 INTRODUÇÃO

O Brasil é um dos principais países produtores e exportadores de *commodities* agrícolas que fornecem insumos importantes para a indústria. Entre eles está o milho, um cereal rico em qualidades nutricionais, muito utilizado como matéria-prima em mercados distintos. Segundo as estatísticas da Produção Agropecuária do país apresentadas pelo Instituto Brasileiro de Geografia e Estatística - IBGE (2022), a produção dessa cultura vem sendo uma das principais atividades econômicas exercidas no setor agropecuário nacional, ocupando o segundo lugar no ranking, ficando atrás apenas da produção de soja.

Para Caldarelli & Bacchi (2012) compreender como se dá a dinâmica de funcionamento de mercado desse insumo, que tem influência direta em diversas instâncias como alimentação, produção de rações, de biocombustíveis, etc. é de grande importância. Dentro do setor agropecuário, que é uma atividade complexa e vulnerável a diversos fatores de risco segundo Sousa *et al.* (2015), faz-se necessário entender o comportamento desses produtos, como as quantidades produzidas e outros fatores que afetam os preços de mercado, a fim de maximizar a chance de maiores receitas e minimizar os riscos na negociação dessa mercadoria, e definir estratégias úteis que darão suporte aos produtores e investidores na tomada de decisões.

Dessa forma, o mercado necessita de métodos que busquem auxiliar na tomada de decisões para desenvolver estratégias que indiquem os melhores momentos para fazer as negociações e/ou formar estoques.

No mercado de derivativos, a base, ou do inglês, “*basis*” refere-se à diferença entre o preço da *commodity* no mercado físico e o preço do mesmo produto no mercado futuro. Seu comportamento de enfraquecimento ou fortalecimento pode indicar uma situação favorável ou desfavorável para a trajetória do produto. Em se tratando de milho no mercado brasileiro, essa medida pode ser calculada pela diferença entre o preço do produto em alguma praça de negociação e o preço na Brasil, Bolsa e Balcão - B3, que é uma bolsa de valores cujas atividades permeiam entre serviços de mercados financeiros e capitais.

Fileni (1999) traz que a falta de conhecimento operacional e as incertezas sobre o comportamento dos preços futuros e à vista podem contribuir para a pequena participação do mercado futuro nos processos de comercialização agrícola. Para Lopes (2018) a predição vem auxiliar essas questões, trazendo conhecimentos úteis e estratégias para a gestão e o controle dos fatores que afetam os preços desses produtos, os melhores períodos para vender ou fazer

estoques, almejando maior rentabilidade e condições mais favoráveis para as negociações. Isso é feito através de métodos que envolvem modelos estatísticos.

Dessa forma, por meio do estudo de séries temporais, é possível analisar os dados de preços de *commodities* agrícolas utilizando seus modelos para compreender a dinâmica do mercado e realizar previsões. A análise de séries temporais explora dados sequenciais de determinada variável ao longo do tempo, e por meio dela é possível identificar informações sobre o comportamento dos dados no decorrer da série como tendências, sazonalidade, flutuações, etc.

As análises são realizadas por meio de modelos que são testados ajustando-se aos dados, dentre eles tem-se o modelo Autorregressivo (AR) que se destaca entre os modelos estatísticos utilizados para a previsão de valores futuros com base em bancos de dados históricos e o modelo de Heteroscedasticidade Condicional AutoRegressiva Generalizada (GARCH) que é um modelo muito utilizado para modelar séries econômicas e/ou financeiras, com o objetivo de realizar a previsão da volatilidade dos retornos desses ativos financeiros.

Alguns trabalhos como o de Tibulo & Carli (2014), utilizam a aplicabilidade do modelo ARIMA para previsão do preço do milho e outros trabalhos como o de Tonin & Alves (2007) utilizam a base de preços de milho para analisar o comportamento dos preços ao longo dos anos, porém não há muitas pesquisas que utilizam séries temporais para modelar e fazer a previsão da base de preço de produtos agrícolas considerando a volatilidade, justificando a importância deste estudo.

A escolha pelo estudo do mercado de milho em Minas Gerais foi motivada pelo fato de ser um dos principais produtos destinados a alimentação do gado leiteiro, sendo essa produção de grande influência nas atividades econômicas do país e de grande destaque nesse Estado, que é o maior Estado produtor segundo o Mapa da Produção do Leite no Brasil de 2022, disponibilizado pelo IBGE.

1.1 Objetivos

O objetivo geral desta pesquisa é ajustar modelos de séries temporais para previsão da base de milho, analisando o comportamento dos preços e da volatilidade em mercados físicos do estado de Minas Gerais. O estudo considera os preços diários (5 dias) do produto no mercado futuro representado pela B3 e nas principais praças produtoras de comércio do estado de Minas

Gerais, a saber: Iraí de Minas, Unaí, Noroeste de Minas, Oeste de Minas, Sudoeste de Minas e Triângulo Mineiro.

Como objetivos específicos, a pesquisa procura:

- Avaliar a potencialidade da utilização de modelos estatísticos de séries temporais na previsão da base do preço do milho;
- Realizar a comparação de modelos, considerando as características de cada série;
- Analisar a volatilidade das séries da base do preço do milho em Minas Gerais e comparar as diferentes praças físicas em relação à dinâmica de mercado.

Os dados utilizados são as bases resultantes da diferença entre os preços dados pelo mercado futuro - B3 e os preços de cada praça de comércio de Minas Gerais considerada. O período temporal considerado foi o de 16/07/2018 a 31/12/2024, escolhido por reunir características que tornam esse intervalo adequado para estudar o comportamento da base e da volatilidade do milho em Minas Gerais. As análises estatísticas foram realizadas utilizando o *software R*.

2 REFERENCIAL TEÓRICO

Neste capítulo, descreveremos brevemente sobre a produção e a importância econômica do milho no país, sobre os mercados e agentes que fazem parte do processo de comercialização deste ativo. Na sequência, são apresentadas as metodologias de análise de séries temporais, bem como os modelos que são utilizados para analisar preços, com ênfase maior nos modelos AR e GARCH, criando um contexto inicial para a compreender ambos.

2.1 Produção nacional de milho e sua importância econômica

Atualmente, o milho é um dos principais grãos produzidos no Brasil, sendo um produto fundamental na agricultura nacional e produzido nas mais diversas regiões, que possuem diferentes climas e condições ambientais, sistemas de produção e contextos socioeconômicos, ressalta Contini *et al.* (2019). O mesmo autor afirma que, com a expansão territorial da produção agrícola no país, o cultivo do milho deixou de ser apenas para subsistência de pequenos produtores rurais, tornando-se uma agricultura comercial eficiente, expandindo-se geograficamente pelos territórios nacionais.

Tonin & Alves (2007, p. 64) afirmam que “A produção de milho é bastante pulverizada, sendo realizada por grande número de produtores de diferentes tamanhos e com diferentes produtividades.” Encontra-se cultivo de milho em praticamente todo o país, revelando a importância desse insumo na alimentação humana. Seu valor alimentício ficou conhecido pela riqueza nutricional de vitaminas e minerais, sendo uma importante fonte energética.

A importância do milho para a economia brasileira está associada à sua versatilidade de uso. O grão é utilizado desde a alimentação animal, na produção de rações, até na indústria tecnológica, permitindo a fabricação de diversos produtos comerciais, como alimentos, bebidas, óleos e combustíveis renováveis. Essa variedade de aplicações destaca o alto valor agregado do produto no setor agrícola do país, tanto em termos econômicos quanto sociais.

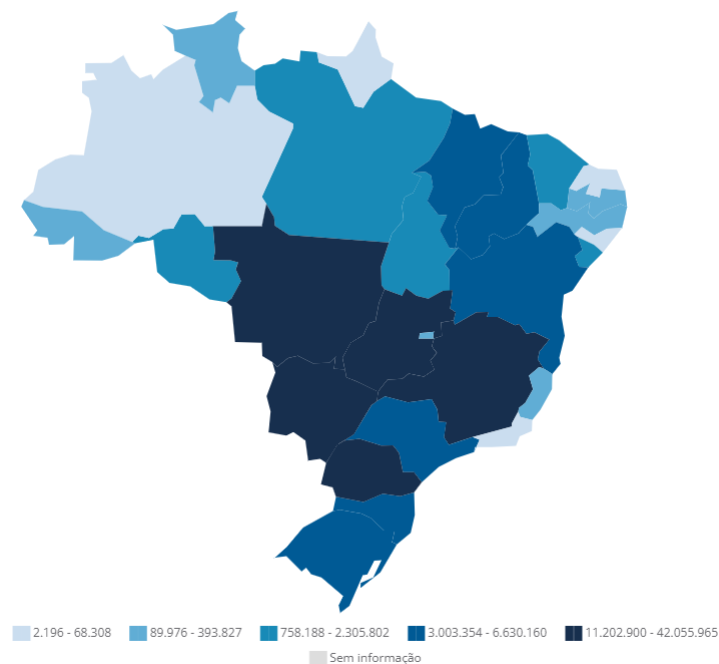
Cruz *et al.* (2010) explica em seu trabalho que a cultura do milho exige bastante água, ou seja, solos ricos em umidade, que vão influenciar diretamente em seu período de crescimento e desenvolvimento. Além disso, fatores como temperatura, radiação solar e fotoperíodo também são determinantes. Sua época de semeadura geralmente começa em janeiro em algumas regiões devido às temperaturas mais elevadas. O milho apresenta dois estágios de desenvolvi-

mento: o vegetativo e o reprodutivo. No estado vegetativo, o grão passa por várias fases para se desenvolver como planta, onde crescem folhas, sua espiga e seu pendão se desenvolvem, e a partir daí pode-se reproduzir resultando no milho. Já no estado reprodutivo, a planta está em seu tamanho máximo e inicia o estágio de florescimento, onde ocorre a projeção dos cabelos para fora da espiga.

Mascarenhas (2021) traz que as principais variedades de milho são: de silagem, pipoca, milho doce, branco e o mini milho. Segundo o Calendário de plantio e colheita de grãos no Brasil apresentado pela Companhia Nacional do Abastecimento - CONAB (2022), a produção de milho no país se concentra nas regiões Centro-Oeste, Sudeste e Sul. As duas principais épocas de plantio ocorrem durante a época chuvosa. A primeira é conhecida como primeira safra, em que o plantio é realizado no final do mês de agosto no Sul e até meados de outubro/novembro nas outras duas regiões. Já a segunda safra, é conhecida popularmente como safrinha ou safra de inverno e é realizada entre janeiro e março.

De acordo com as estimativas apresentadas pelo IBGE (2024), os principais estados produtores são Mato Grosso, Paraná, Rio Grande do Sul, Goiás, Mato Grosso do Sul e Minas Gerais, como representado na Figura 2.1.

Figura 2.1 – Mapa do Valor da Produção de Milho em Grão no Brasil 2022 (Mil Reais).



Fonte: IBGE

Com a crescente expansão dessa cultura, proveniente da valorização do grão, a atividade comercial passou a ganhar visibilidade tanto no cenário nacional como internacional. Isso impulsionou a produção em alta escala e trouxe o Brasil para um nível de maior competitividade internacional.

Diferentes cadeias dependem do milho em diversas formas, entre elas está a silagem, uma vez que se utiliza a planta inteira, usualmente destinada à alimentação dos animais, o grão e ultimamente vem sendo utilizado para a produção de etanol e Grãos Secos de Destilaria com Solúveis (DDGS), revelando a importância do milho para as regiões agrícolas trazendo novas oportunidades de negócios (Contini *et al.*, 2019, p. 14).

Tonin & Alves (2007, p. 64) ressaltam que “O cereal está na base de várias cadeias produtivas e é um elo estratégico de extrema importância para as cadeias de avicultura de corte e postura, suinocultura, bovinocultura de corte e leite, alimentação humana, entre outras cadeias produtivas”.

Um dos principais destinos do milho é para a pecuária leiteira, sendo a silagem do milho um dos principais insumos alimentícios oferecidos aos bovinos que produzem leite. Por conta da sua grande concentração de amido, em base seca, o cereal fornece alta capacidade de energia fazendo parte da dieta nutricional do animal.

O amido presente no cereal apresenta alta disponibilidade energética e é fundamental na alimentação dos animais de alta produção, por conta da exigência de altos níveis de energia (Pereira; Antunes, 2007, p. 49).


Segundo Scheler & Cavichioli (2021) a silagem do milho permite que se retire a cultura da lavoura mais cedo, permitindo adotar um esquema de rotação de culturas e assim reduzir perdas significativas no campo. Além de ser uma boa opção para os períodos mais secos, a produção do milho de silagem permite melhor capacidade de armazenamento por ser compacto, ter custos razoáveis de produção, alto valor nutritivo e boa aceitação dos animais, sendo um alimento mais palatável e mais digestível que os demais insumos (RevistaAgropecuaria, 2019).

A alimentação animal é um dos principais destinos do milho. Dessa forma, a produção dessa cultura e suas negociações impactam diretamente na produção leiteira do país, visto que o cereal é um dos principais elementos presentes na cadeia produtiva e seus custos são significativos na alimentação do gado de leite.

A produção leiteira no Brasil é uma das atividades econômicas mais importantes do país, e segundo o Mapa da Produção do Leite no Brasil - IBGE (2022) o estado de Minas

Gerais está entre os maiores estados produtores de leite do país (Figura 2.2), com o valor da produção em 2022 igual a 80.043.813 mil Reais e a quantidade produzida nesse mesmo ano, igual a 34.609.218 mil litros.

Figura 2.2 – Mapa do Valor da Produção do Leite no Brasil 2022 (Mil Reais).




Fonte: IBGE

Silva, Souza & Martins (2012) ressaltam que Minas Gerais é um estado marcado pelas atividades produtivas e a produção de leite pode ser considerada uma tradição no Estado devido aos elevados números de produção. Um dos principais destinos do leite *in natura* é para a fabricação de laticínios, que tem uma alta demanda de leite em sua fabricação.

É perceptível a forte influência e importância que o Estado de Minas Gerais representa para a agricultura nacional. Segundo o Ranking de Produção Agropecuária 2022 disponibilizado pelo IBGE (Figura 2.3) as principais culturas produzidas pelo Estado de Minas Gerais são o café, a soja, o milho em grão e a cana-de-açúcar, seguidos de outras culturas em menor escala de produção.

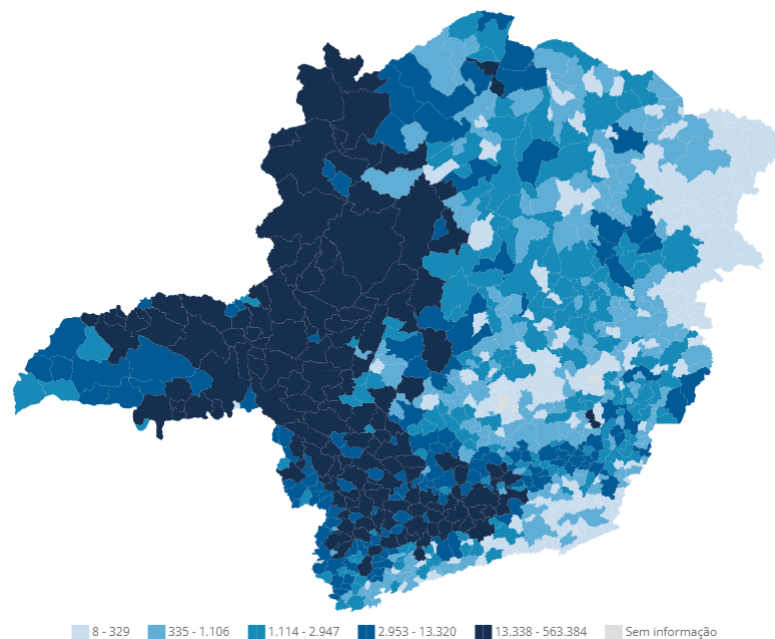
Figura 2.3 – Ranking do Valor da Produção das culturas de Minas Gerais 2022 (Mil Reais).



Fonte: IBGE

Segundo Garcia, Mattoso & Duarte (2006, p. 8) “A produção de milho em Minas Gerais está concentrada nas regiões situadas no Sul e no Oeste do Estado, como o Sul de Minas, Triângulo, Alto Paranaíba e Noroeste” (Figura 2.4). Essa concentração facilita a produção por serem regiões com climas favoráveis e também pela organização de mercado, que facilita introduzir novas tecnologias nas lavouras, promovendo competição entre as regiões produtoras, além das facilidades de transporte e comercialização que a região possui.

Figura 2.4 – Mapa do Valor da Produção do milho em Minas Gerais 2022 (Mil Reais).



Fonte: IBGE

Diante desse cenário de expansão, e considerando a importância econômica do milho para Minas Gerais — especialmente por ser um dos principais insumos utilizados na alimentação do gado leiteiro — justifica-se o interesse em analisar as estratégias de comercialização adotadas nas principais regiões produtoras do estado. Além disso, torna-se relevante buscar métodos que possibilitem a compreensão do comportamento dos preços por meio de modelos estatísticos, contribuindo para uma gestão mais eficiente da produção e da comercialização da *commodity*.

2.2 Mercados e Agentes

A atividade agropecuária, por ser complexa e vulnerável, está sujeita a diversos fatores de risco na sua produção e comercialização, como mudanças climáticas, doenças, pragas, etc., que influenciam diretamente nas técnicas de cultura, na qualidade da produção e principalmente no preço do produto.

Tonin & Alves (2007) trazem em seu trabalho que por conta desses riscos, o produtor se vê diante de um cenário incerto, onde a produção se torna instável e não é possível estimá-la, então o preço estará sujeito às oscilações e variações que irão impactar diretamente no retorno lucrativo do produtor. Não são apenas os riscos relacionados às condições serem favoráveis ou não para o cultivo que influenciam diretamente no preço da mercadoria. O autor ainda ressalta que “Além da questão de risco e incerteza e mudanças especulativas no preço, o produtor se depara com constantes modificações de preços devidas à sazonalidade e ao excesso ou escassez do produto” (Tonin; Alves, 2007, p. 61).

Uma das principais características da atividade agropecuária é a sazonalidade, definida como a repetição de determinados padrões ou comportamentos que ocorrem em períodos específicos do tempo. De acordo com Soares *et al.* (2004), a sazonalidade manifesta-se por meio da recorrência de situações ao longo de dias, meses ou anos, influenciando diretamente a produção agrícola. Na maioria dos casos, são as estações do ano que determinam esses ciclos, interferindo nas culturas agrícolas e na dinâmica do setor como um todo.

Os autores destacam ainda que “os produtos agroindustriais são dependentes do comportamento sazonal da oferta agrícola. A velocidade da produção, das vendas e a formação de estoques estão de acordo com a velocidade especificada pelas estações do ano” (SOARES *et al.*, 2004, p. 4).

Esse comportamento sazonal afeta não apenas a produção, mas também os preços dos produtos ao longo do ano, sendo fortemente influenciado pelos períodos de safra e entressafra. No caso do milho, por exemplo, os períodos mais propícios ao cultivo coincidem com as estações chuvosas. A primeira safra tem início, geralmente, em agosto, enquanto a segunda, conhecida como safrinha, ocorre a partir de janeiro. Já a entressafra corresponde ao intervalo entre uma colheita e outra do mesmo produto, sendo caracterizada por uma menor oferta no mercado e, conseqüentemente, maior oscilação nos preços. Como afirmam os autores, a “entressafra é o período que medeia entre uma safra e outra imediata, de determinado produto” (SOARES et al., 2004, p. 5).

Tonin & Alves (2007) destacam que no período de entressafra o preço dos produtos são mais altos devido a baixa disponibilidade e os preços mais baixos são nas épocas de mais ofertas, que ocorrem durante o período de safra. E por conta da pouca experiência de negociação e comercialização por parte do produtor, acabam vendendo a maior parte da produção logo após a colheita, nos períodos de preço baixo, principalmente pela pouca capacidade de armazenamento em sua propriedade.

A formação do preço do milho também é influenciada pela oferta e pela demanda. Conforme explicam (Sanches; Barros; Alves, 2018), os preços do milho no Brasil são muito sensíveis a mudanças nessas duas variáveis, especialmente em nível regional. Como o consumo interno tem grande importância, isso faz com que os preços variem bastante, essas variações acabam provocando grandes oscilações nos preços, que tendem a subir quando há queda na oferta e a cair quando a oferta aumenta.

É importante levar em conta que os preços dos produtos agrícolas não são formados apenas pelas influências dos períodos de produção, mas também são influenciados pelos fatores de clima, de oferta e procura.

Essa alternância entre os períodos influencia diretamente nas oscilações dos preços, pois quando há produtos em excesso disponíveis no mercado, o preço tende a cair para que o consumidor seja induzido a consumi-lo, mas se os produtos estão em falta, o preço aumenta, limitando assim o seu consumo de acordo com a pouca disponibilidade (Soares *et al.*, 2004).

Outro fator importante na determinação do preço do milho é a sua forte interação com o mercado de soja. “Embora tenham características distintas, os mercados de milho e soja apresentam fatores de interação, seja de substitutibilidade na oferta – competindo principalmente

pelo fator terra –, seja de complementaridade na demanda – composição de rações” (Caldarelli; Bacchi, 2012, p. 142).

Silva *et al.* (2017) explica que essa complementaridade se dá pelo sistema de rotação dos cultivos dessas culturas pois a soja é semeada antes do milho, outro fator considerado pode ser devido ao preço elevado que a soja tem atingido nos últimos anos sendo o milho uma opção para substituição.

“Como as demais *commodities* agrícolas, a produção e comercialização de milho estão suscetíveis a uma série de riscos intrínsecos a esse setor, como o risco de preço” (Tonin; Braga; Coelho, 2009, p. 118). Assim, o mercado necessita de ferramentas e mecanismos para que tanto o produtor como o comprador possam se proteger dos riscos que essas oscilações de preço causam e para auxiliar na tomada de decisões no processo de negociação, possibilitando assim desenvolver estratégias que possam indicar os melhores momentos para fazer as negociações e para formar estoques.

“Os mercados futuros e opções permitem que os agentes envolvidos nessa atividade minimizem os riscos de preço relacionados às oscilações indesejadas que acarretam perdas durante o período dos seus empreendimentos” (Tonin; Alves, 2007, p. 72). O objetivo principal é garantir o melhor preço possível para que o produtor maximize sua venda e possibilitar que o comprador também tenha acesso a compra com o menor preço possível das mercadorias.

Segundo Cruz & Macedo (2002, p. 2) “O mercado futuro agropecuário é um mercado em que são transacionados contratos de produtos agropecuários específicos com um preço determinado para uma data futura”, ou seja, por meio do mercado futuro são realizados contratos de negócio entre o produtor e o comprador, onde assumem o compromisso na data presente sobre determinados produtos com preço fixo e com prazos que serão realizados no futuro, eliminando assim a possibilidade de variação no preço.

Para Cruz & Macedo (2002) as principais características do mercado futuro são a existência de contratos padronizados, os ajustes diários e as margens de garantia que vão dar segurança para os participantes no processo de comercialização do produto. Assim os envolvidos negociam a compra e venda da mercadoria, independente de se possuir ou não o objeto (mercadoria, bem, valor) na data em que o negócio está sendo firmado, exigindo apenas uma garantia de que ambos irão cumprir o acordo firmado.

Os *hedges* são os agentes que visam diminuir os riscos de preço, os especuladores objetivam obter lucros, apostam na alta ou queda dos preços, assumindo o risco dessas oscilações e

os arbitradores são agentes que aproveitam a discrepância entre os preços de mercados distintos. Dessa forma, os riscos são transferidos para os especuladores e os arbitradores buscam nessas oportunidades conseguir *traders*, comprando com preços baixos e vendendo mais caro.

São os contratos futuros que regulamentam as negociações no mercado futuro. Os contratos futuros são um tipo de derivativo negociado nos mercados financeiros globais, consistindo em acordos para compra e venda de um ativo em uma data futura definida, com preço estabelecido antecipadamente.

“Os contratos derivativos podem ser celebrados em mercados organizados (ex: bolsas de valores e mercado de balcão) ou ser negociados de forma bilateral diretamente entre as partes envolvidas” (Brasil, 2015, p. 12). Para Sanches, Barros & Alves (2018, p. 2) “O contrato foi lançado para que os agentes consigam, através da negociação simultânea com o contrato futuro de liquidação financeira, aumentar a eficiência da proteção contra oscilações indesejadas de preço”.

Então, a fim de neutralizar os impactos causados pelas diversas variações nos preços surge o mecanismo *hedge*, que vem como uma estratégia de gestão de preços em ambientes de incerteza, a fim de administrar os riscos de perdas relativas e significantes nos processos de comercialização. Assim, para Tonin & Alves (2007, p. 74) “Os produtores e outros agentes que têm interesse no produto participam do mercado futuro assumindo a posição de *hedger*”.

Neto & Barbosa (2024, p. 5) trazem o conceito de *hedge* como sendo "... uma operação que envolve a tomada de uma posição contrária à posição no mercado físico ou a vista, visando minimizar o risco financeiro decorrente das possíveis oscilações de preços de determinada *commodity*", buscando assim minimizar os riscos causados por ações adversas nos preços que acarretam em perdas financeiras.

As operações realizadas pelos mercados futuros são operadas pelas bolsas de valores. A Brasil, Bolsa e Balcão - B3 é uma empresa de mercado financeiro que atua em ambiente de bolsa e de balcão, suas atividades permeiam sistemas de negociação, compensação, entre outros serviços voltados para as mais importantes classes de ativos.

Paralelamente à atuação das bolsas, existem instituições dedicadas à produção de indicadores de preço, que são gerados por grupos cuja atividade é voltada para pesquisas e informações sobre dados. Podemos citar o Centro de Estudos Avançados em Economia Aplicada - CEPEA que faz parte do Departamento de Economia, Administração e Sociologia da Escola Superior de Agronomia Luiz Queiroz - Esalq/USP, voltado ao setor rural e que realiza pes-

quisas sobre o agronegócio. Há, também, a Companhia Nacional de Abastecimento - CONAB, uma empresa sediada em Brasília, vinculada ao Ministério do Desenvolvimento Agrário e Agricultura Familiar, que participa da formulação e execução de políticas públicas voltadas para o abastecimento e formação de renda do produtor rural.

2.2.1 A base

A interação e comercialização de mercadorias entre os mercados futuros e os mercados físicos — compostos por praças de produção e comércio, que são distribuídas e organizadas, geralmente, de acordo com a proximidade das regiões — desempenham papel central na formação dos preços das *commodities*.

Nesse contexto, Tonin & Alves (2007) observam que, ao se operar com mercados futuros agropecuários, torna-se evidente que os preços praticados em uma determinada região podem diferir dos preços observados nos mercados futuros. Essa diferença é conhecida como base, e sua análise é essencial para compreender a relação entre os dois mercados.

Dada a dificuldade de prever os preços de *commodities* como o milho, diversos autores têm adotado modelos de séries temporais para analisar e avaliar o comportamento da base. No mercado de derivativos, entende-se por base (ou *basis*, em inglês) a diferença entre o preço à vista do produto no mercado físico e o preço negociado no mercado futuro. O fortalecimento ou enfraquecimento da base pode sinalizar situações mais ou menos favoráveis à trajetória dos preços, sendo uma variável de grande relevância na tomada de decisão.

Tonin & Alves (2007) também ressaltam que, para que as operações com contratos futuros funcionem como proteção contra oscilações de preços, é necessário que os preços futuros acompanhem os preços praticados nos mercados físicos. Caso isso não ocorra, os agentes correm o risco de não obter o retorno financeiro esperado.

Além disso, Auriglietti & Tonin (2021, p. 1) afirmam que “Como o comportamento de base não é constante, dado que os preços físicos e futuros dividem a mesma trajetória, mas apresentam oscilações em diferentes intensidades, há o risco de base”. Os riscos de base podem ter diversas origens, como fatores sazonais, excesso ou escassez temporária do produto, mudanças na demanda e outras condições específicas de mercado. Segundo Barros & Aguiar (2005, p. 447), “A análise do risco de base também é importante para tomada de decisão, pois quanto

menor o risco da base, maior confiabilidade existe em se utilizar seu comportamento histórico como referência para se projetar seu valor futuro”.

Tonin & Alves (2007) também observam que há componentes aleatórios que afetam diretamente a formação da base, como os custos de transporte, armazenamento, mão de obra e a localização das praças de comércio. Esses fatores são variáveis no tempo e no espaço, dificultando a previsão exata da base e, conseqüentemente, dos resultados das operações de *hedge*. O autor complementa afirmando que esses componentes também incluem mudanças estruturais no mercado, como desequilíbrios entre oferta e demanda, intervenções governamentais e adversidades climáticas, fatores que são, em geral, de difícil mensuração.

Outro ponto importante, conforme destaca Fontes, Junior & Azevedo (2005, p. 384), é que a base pode ser positiva — quando o preço à vista da localidade é superior ao do mercado futuro — ou negativa, quando ocorre o inverso. O comportamento da base reflete, assim, diferentes condições de mercado. Quando o preço no mercado físico supera o do mercado futuro, diz-se que a base está fortalecida, indicando uma situação mais favorável para o vendedor. Já quando o preço no mercado físico é inferior ao do futuro, ocorre o enfraquecimento da base, o que pode ser vantajoso para quem compra, mas desfavorável para quem vende.

Dessa forma, quanto menor for o risco de base, maior será a utilidade dos contratos futuros como instrumento de transferência de risco, pois proporcionam maior segurança na definição de preços para os *hedgers*, ampliando a eficiência do mercado derivativo como ferramenta de gestão da comercialização (Fontes; Junior; Azevedo, 2005, p. 384).

Conhecer e acompanhar as variações da base, é essencial para identificar oportunidades de lucro e perda, possibilitando a formulação de estratégias mais sólidas no uso dos mercados futuros e otimizando os resultados das operações.

Nesse sentido, conforme aponta Lopes (2018), os modelos de previsão por séries temporais contribuem significativamente para lidar com as constantes oscilações e incertezas do mercado, auxiliando na tomada de decisão. Esses modelos oferecem informações úteis tanto para compradores quanto para vendedores, favorecendo a formulação de estratégias de gestão e controle sobre os fatores que influenciam os preços das *commodities*.

Com isso, torna-se possível identificar os momentos mais adequados para investir, vender ou formar estoques, buscando maior rentabilidade e condições mais favoráveis para as negociações.

2.3 Modelos de Séries Temporais para análise de preços

Visando buscar meios que auxiliem o mercado na tomada de decisões, um caminho natural para a análise dos dados de preço de *commodities* agrícolas são os métodos que envolvem modelos de séries temporais para o estudo e a predição, analisando a volatilidade dos dados.

Para Lopes (2018) é importante conhecer como os preços se comportam pois são úteis na hora de tomar decisões para o planejamento da produção, criando estratégias que possibilitem maximizar os lucros tanto nas fases de alta como nas fases de baixa.

A previsão de preços possibilita obter informações a fim de minimizar os riscos de investimentos, além de contribuir fortemente nos volumes de negociação através dos modelos de previsão que entregam análises de preços eficientes e confiáveis.

Essas análises se tornam úteis na tomada de decisões indicando os tipos de investimentos que se pode fazer, a hora certa para realizar vendas, planejamentos de produção e formação de estoques, sendo uma estratégia eficiente para que o produtor saiba como agir e o que fazer nas fases de alta e principalmente nas fases de baixa dos preços.

Neste trabalho, busca-se compreender como funciona a dinâmica da base dos preços do mercado de milho em Minas Gerais usando modelos de séries temporais. Portanto, nessa seção são apresentados conceitos importantes associados a esses métodos.

Morettin & Tolo (2006) definem “Uma série temporal é qualquer conjunto de observações ordenadas no tempo”, ou seja, é uma coleção de dados coletados em intervalos regulares de tempo. Geralmente, essas séries são compostas por uma unidade de medida, um fato observado ou analisado e uma unidade de tempo.

Entre os principais objetivos da análise de séries temporais, destacam-se a previsão de valores futuros da série, a descrição do seu comportamento por meio de ferramentas como gráficos, histogramas e diagramas de dispersão, bem como a identificação de tendências, ciclos, variações sazonais e possíveis periodicidades relevantes nos dados (Morettin; Tolo, 2006).

As séries podem ser univariadas, apresentando apenas uma variável conectada ao tempo, ou multivariadas, quando possuem duas ou mais variáveis conectadas ao tempo. Geralmente, são utilizadas para compreender fenômenos, prever eventos e/ou valores futuros com base em observações passadas. Sua estrutura apresenta dados sequenciais, cuja frequência pode ser em horas, dias, semanas, meses, etc. Além disso, as séries podem conter também valores

conhecidos com *outliers*, que são valores atípicos que possuem notável diferença dos demais, ou seja, algum dado fora do padrão.

Séries estacionárias apresentam média e variância constantes ao longo do tempo. Séries que possuem tendência e sazonalidade não são estacionárias. Existem técnicas analíticas de séries temporais que dependem da estacionariedade da série. Se a série não é estacionária, em alguns casos, pode-se aplicar algum tipo de transformação para torná-la estacionária.

Para as séries de preços, como seus objetivos de análises geralmente são para avaliar os riscos, e estes frequentemente são medidos de acordo com as variações dos preços das mercadorias, define-se retorno como sendo essas variações que ocorrem entre um instante e outro. Prefere-se trabalhar com o retorno das séries do que com os preços, pois possuem propriedades estatísticas mais interessantes como estacionariedade e ergodicidade (Morettin; Toloí, 2006).

Um conceito importante relacionado aos dados dispostos em séries temporais é o de autocorrelação, a autocorrelação em dados de preços refere-se à relação entre os valores passados com os valores presentes da variável em estudo. Seus valores devem estar entre 1 e -1, sendo 0 a ausência de autocorrelação.

As medidas utilizadas para o cálculo da autocorrelação são as funções de autocorrelação (FAC/ACF) e de autocorrelação parcial (FACP/PACF), que auxiliam a encontrar padrões significativos nos retornos e a definir os modelos estatísticos.

A FAC expressa o grau de correlação entre os valores de uma série temporal e seus próprios valores defasados ao longo do tempo. Por sua vez, a FACP mede a correlação entre a série e um determinado lag específico, isolando o efeito das demais defasagens intermediárias.

Morettin & Toloí (2006) dividem os métodos de previsão em duas categorias, os Automáticos: aplicados diretamente através de programas de computador e os Não-automáticos: aplicados através da intervenção pessoal.

Dos métodos usados, Morettin & Toloí (2006) separam os modelos automáticos em duas classes, de acordo com o número de parâmetros que envolvem Modelos paramétricos e Modelos não-paramétricos.

Como modelos paramétricos Morettin & Toloí (2006) listam os modelos frequentemente mais usados: Modelos de erro ou regressão; Modelos autoregressivos e de médias móveis - ARMA; Modelos autoregressivos integrados e de médias móveis - ARIMA; Modelos de memória longa - AFIRMA; Modelos estruturais; Modelos não lineares.

Dentre os modelos citados, os escolhidos para serem utilizados na modelagem deste trabalho são: O Modelo autoregressivo e de médias móveis - ARMA e o Modelo autoregressivo integrados e de médias móveis - ARIMA, além dos modelos com Heteroscedasticidade Condicional AutoRegressiva Generalizada (GARCH).

2.3.1 O modelo AR e o modelo MA

A análise de séries temporais é fundamental para a compreensão da dinâmica da base de preços do milho, uma vez que padrões de dependência temporal ajudam a explicar oscilações persistentes entre o preço futuro negociado na B3 e o preço físico observado nas regiões produtoras de Minas Gerais.

Modelos autorregressivos (AR), de médias móveis (MA) e a combinação de ambos (ARMA) constituem a classe mais tradicional para modelagem de séries estacionárias. A formulação desses modelos segue a abordagem clássica, sendo amplamente utilizada em estudos econômicos e financeiros.

O modelo autoregressivo (AR) é uma das estruturas fundamentais na análise de séries temporais e descreve situações em que os valores presentes de uma variável dependem de seus próprios valores passados. Ou seja, o modelo AR assume que há uma relação direta entre o comportamento atual da série e seu histórico recente.

Arce & Mahia (2003) definem que um modelo autorregressivo de ordem p , denotado por $AR(p)$, é dado por:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t, \quad (2.1)$$

em que $e_t \sim RB(0, \sigma_e^2)$ e Y_t representa o valor da série no tempo t ; $\phi_1, \phi_2, \dots, \phi_p$ são os parâmetros do modelo, responsáveis por medir a influência de cada defasagem passada sobre o valor atual; e_t é o termo de erro aleatório, assumido como ruído branco com média zero e variância constante.

Na forma compacta, utilizando o operador de defasagem B :

$$\phi(B)Y_t = e_t, \quad (2.2)$$

com

$$\phi(B) = 1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p. \quad (2.3)$$

sendo B o operador da defasagem.

O termo “autoregressivo” reflete o fato de que a variável depende de si mesma em períodos anteriores. Esse tipo de modelo é especialmente útil quando a série apresenta correlação temporal significativa, ou seja, quando valores próximos no tempo tendem a estar relacionados.

Um modelo AR captura o grau de persistência temporal da base. Isso significa que: se ϕ_1 é alto, uma base positiva tende a permanecer positiva por mais tempo (persistência), oscilações de curto prazo são explicadas pela própria dinâmica histórica do mercado, o modelo ajuda a identificar períodos em que o mercado apresenta previsibilidade, refletindo eficiência operacional entre mercado físico e futuro, segundo Nardino & Figueiredo (2021).

Já um modelo de médias móveis de ordem q , $MA(q)$, é definido por:

$$Y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}, \quad (2.4)$$

ou, de forma equivalente,

$$Y_t = \theta(B)e_t, \quad (2.5)$$

em que

$$\theta(B) = 1 - \theta_1 B^1 - \dots - \theta_q B^q. \quad (2.6)$$

Segundo Campos (2007a) os modelos MA são úteis para representar: impactos pontuais de choques de oferta (clima, safra, logística), movimentos abruptos no preço futuro decorrentes de notícias externas, ajustes rápidos resultantes de erros de previsão do mercado.

Os modelos AR e MA são apropriados para descrever series estacionárias, entretanto muitas séries encontradas na pratica são não estacionárias.

2.3.2 O modelo ARMA e o modelo ARIMA

Uma das metodologias mais utilizadas na análise de modelos paramétricos em séries temporais é a abordagem de Box-Jenkins (1970), que se desenvolve em três passos: Identificação, Estimção e Teste.

Essa metodologia foi proposta por Box-Jenkins e é apropriada para descrever séries estacionárias ou não estacionárias. Ela consiste em ajustar modelos autorregressivos integrados de médias móveis, ARIMA(p,d,q), ao conjunto de dados temporais.

Considera-se que uma série é estacionária quando a média e a variância são constantes ao longo do tempo, caso contrário, é uma série não estacionária. Caso a série seja não estacionária, pode-se tentar eliminar a tendência por meio do processo de diferenciação, que consiste em aplicar uma ou mais diferenças aos dados. Entretanto, ressalta-se que nem todas as séries tornam-se estacionárias mesmo após a diferenciação, especialmente aquelas que apresentam características estruturais mais complexas.

No modelo ARIMA (p, d, q), seu componente p é o número de termos da parte autorregressiva AR(p), q é o número de termos da parte de médias móveis MA(q) e d o número de diferenças sucessivas.

Morettin & Tolo (2006) trazem que um modelo ARMA (p,q) apresenta poucos parâmetros e é descrito pela forma,

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.7)$$

Sendo, Y_t o valor observado da série temporal no tempo t ; ϕ_i os coeficientes AR (autorregressivos); θ_j os coeficientes MA (médias móveis) e e o erro aleatório (ruído branco).

E o modelo apresenta as seguintes características:

- I) É estacionário se as raízes do polinômio $\phi(B) = 0$ estiverem fora do círculo unitário.
- II) É invertível se as raízes do polinômio $\theta(B) = 0$ estiverem fora do círculo unitário.

Então, Morettin & Tolo (2006) revela que se a série $W_t = \Delta^d Y_t$ for estacionária, podemos representar W_t por um modelo ARMA (p,q), ou seja,

$$\phi(B)W_t = \theta(B)e_t \quad (2.8)$$

em que, W_t é a série estacionária obtida após diferenciação e B o operador defasagem.

Assim, se W_t for uma diferença de Y_t , então dizemos que Y_t segue um modelo autorregressivo integrado de médias móveis de ordem (p,d,q) e escrevemos ARIMA(p,d,q),

$$\phi(B)W_t = \theta(B)e_t \quad (2.9)$$

sendo equivalente:

$$\phi(B)(1-B)^d Y_t = \theta(B)e_t \quad (2.10)$$

Assim, se $d = 0$, Y_t é estacionário e na maioria das vezes d é igual a 1 ou 2.

As características de séries estacionárias são:

a) Quanto ao nível: oscilam ao redor de um nível médio durante algum tempo e depois saltam para outro nível temporário. Para torná-las estacionárias é suficiente tomar uma diferença;

b) Quanto à inclinação: oscilam numa direção por algum tempo e depois mudam para outra direção temporária. Para torná-las estacionárias tomar 2 diferenças.

Após o ajuste de um modelo, é necessário verificar se ele fornece uma descrição adequada dos dados. Então deve-se verificar o comportamento dos resíduos assim como na aplicação de outros modelos estatísticos, sendo o resíduo a diferença entre o valor observado e o valor ajustado (Ehlers, 2007).

Então, se o modelo estiver bem ajustado é esperado que os resíduos sejam distribuídos aleatoriamente em torno de zero e sua variância seja aproximadamente constante, sendo não correlacionados. Para verificar se o modelo é adequado ou não pode-se representar os resíduos e o correlograma graficamente, permitindo uma análise mais detalhada da estrutura de autocorrelação do modelo.

Outra maneira de verificar é através do uso do teste de Box-Pierce para as hipóteses, que testa se um grupo de autocorrelações é significativamente diferente de zero.

Uma das utilidades do modelo ajustado é para realizar previsões para valores futuros baseados nos valores passados. Essas previsões podem ser feitas tanto para fora quanto para dentro do período amostral, para comparação com os valores observados, sendo uma estratégia muito útil para checar o desempenho preditivo do modelo (Ehlers, 2007).

Se a análise indicar que os resíduos dos modelos ARIMA apresentam heterocedasticidade, ou seja, variância não constante ao longo do tempo, mostra a necessidade de utilizar modelos que considerem essa característica, como o GARCH. Modelos tradicionais assumem resíduos homocedásticos. O modelo GARCH é especialmente adequado para capturar a variabilidade condicional da variância, possibilitando a modelagem de períodos de maior ou menor volatilidade, comuns em séries temporais econômicas e financeiras, como a dos preços do milho.

2.3.3 O modelo ARCH e o modelo GARCH

A análise da volatilidade condicional em séries temporais financeiras pode ser realizada por meio do modelo *Generalized Autoregressive Conditional Heteroskedasticity* - GARCH, proposto por Bollerslev (1986), como uma extensão do modelo ARCH de Engle (1982). Essa classe de modelos é amplamente utilizada para capturar a variância condicional heterocedástica ao longo do tempo, observada frequentemente em séries financeiras e econômicas.

O modelo GARCH(p, q) assume que a variância condicional da série no tempo t denotada por σ_t^2 , depende linearmente de choques passados (termos ARCH) e de variâncias condicionais passadas (termos GARCH). Silva (2021) descreve o modelo:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2.11)$$

Em que, σ_t^2 é a variância condicional no tempo t ; $\omega > 0$ é o termo constante; $\alpha_i \geq 0$ são os coeficientes dos termos ARCH (impacto dos choques passados); ε_{t-i}^2 são os quadrados dos resíduos (inovações) passadas; $\beta_j \geq 0$ são os coeficientes dos termos GARCH (memória da variância passada); p é a ordem da parte GARCH (variância condicional passada); q é a ordem da parte ARCH (choques anteriores).

Após a estimação do modelo GARCH, é essencial avaliar se a especificação adotada é capaz de capturar adequadamente a volatilidade condicional da série temporal. Para isso, diferentes testes e diagnósticos são aplicados aos resíduos padronizados.

O Primeiro, é o Teste ARCH (Lagrange Multiplier). Esse teste verifica a presença remanescente de heterocedasticidade condicional nos resíduos. Um valor p elevado indica que não há evidência de efeitos ARCH residuais, sugerindo que o modelo GARCH conseguiu absorver a maior parte da dinâmica de volatilidade da série.

Em seguida, é preciso verificar a ACF dos resíduos padronizados. A análise da ACF permite identificar possíveis padrões de correlação temporal não explicados pelo modelo. A ausência de autocorrelação estatisticamente significativa sinaliza que o componente de média e o próprio GARCH foram corretamente especificados.

Avalia-se Função de Autocorrelação dos resíduos ao quadrado. Esse diagnóstico avalia a autocorrelação na variância. A inexistência de padrões significativos na ACF dos resíduos ao

quadrado indica que não há estrutura de volatilidade não capturada pelo modelo, reforçando sua boa adequação.

Também é utilizado o QQ-Plot dos resíduos padronizados. O gráfico quantil-quantil é utilizado para avaliar a aderência dos resíduos à distribuição assumida na estimação do modelo (normal, t-Student, GED etc.). Quanto mais os pontos se aproximam da linha de referência, melhor é a conformidade da distribuição dos resíduos, o que sustenta a qualidade do ajuste.

Por fim, aplica-se o Teste de Ljung-Box aplicado aos resíduos e aos resíduos ao quadrado. Esse teste verifica a presença de autocorrelação linear e não linear. P-valores superiores ao nível de significância adotado indicam que os resíduos são independentes, sugerindo que o modelo GARCH capturou de forma satisfatória tanto a dinâmica da média quanto da variância condicional.

Esses diagnósticos, em conjunto, permitem avaliar se a modelagem da volatilidade foi eficiente e se o modelo pode ser considerado adequadamente especificado para fins de análise e previsão.

Após realizar essas etapas e verificar se todas se mostraram adequadas na modelagem da volatilidade condicional da série temporal analisada, então temos que os resultados indicam que o modelo ajustado captura adequadamente a dinâmica da volatilidade ao longo do tempo, permitindo previsões e análises de risco mais precisas. Tornando assim, a abordagem GARCH uma ferramenta estatística essencial para o estudo de séries financeiras e econômicas com comportamento volátil.

2.3.4 Modelos de Séries Temporais na predição de preços e de bases de *commodities* agrícolas

Diversos estudos abordaram a análise da base de preços de *commodities* agrícolas no Brasil, especialmente do café e do milho, utilizando tanto abordagens estatísticas quanto econômicas.

Fileni, Marques & Machado (1999) avaliaram os riscos de mercado e o papel dos especuladores na comercialização de café em Minas Gerais, com base nos contratos futuros negociados na Bolsa de Mercadorias & Futuros (BM&F). O estudo considerou informações sobre a base e o risco de base para analisar a efetividade do uso do *hedge*. Os autores concluíram que os riscos de base variam conforme o mês, e que os agentes de comercialização devem estar atentos

a essa sazonalidade. Além disso, verificou-se que o contrato analisado se mostrou eficaz para a mitigação dos riscos, e que o uso de técnicas de monitoramento e de informações de mercado pode potencializar os benefícios do *hedge*.

Fontes, Junior & Azevedo (2005) analisaram a base de preços em municípios produtores de café nos estados de Minas Gerais e São Paulo, como Boa Esperança, Caratinga, Lavras, Machado, Patrocínio, Três Pontas, Varginha e Garça. O objetivo foi mensurar os valores da base e do risco de base, utilizando dados da BM&F referentes ao período de setembro de 1994 a julho de 2001. Os autores destacaram que o uso da base como ferramenta auxiliar na tomada de decisão é essencial para aumentar a confiabilidade nas expectativas de preço. Os resultados revelaram grande variabilidade nos preços, influenciada pelas características regionais de cada localidade.

Barros & Aguiar (2005) utilizaram a base de preços diários do café arábica das regiões do Sul de Minas, Cerrado Mineiro, Paulista, Mogiana e Paraná, no período de junho de 1998 a dezembro de 2003. Os dados de preços futuros foram obtidos no CEPEA. O estudo teve como objetivo analisar o comportamento da base e oferecer subsídios para a formulação de estratégias de *hedge*, identificando períodos de base forte ou fraca, o que fornece informações valiosas para a tomada de decisão dos produtores de café.

Tonin & Alves (2007) realizaram uma análise da base de preço do milho na região de Maringá – PR, com dados do período de 2002 a 2004, e informações de preços futuros retiradas da BM&F. O estudo verificou o comportamento oscilante dos preços ao longo do ano e teve como foco a apresentação de instrumentos de apoio à comercialização do grão, por meio da mensuração da base. Destaca-se a importância da relação entre os preços dos mercados físico e futuro para as operações de *hedge*, sendo o trabalho considerado como um primeiro passo para análises mais aprofundadas sobre a efetividade e a razão ótima de *hedge* para o milho na região analisada.

Campos (2007b) aplica modelos da classe ARCH/GARCH às séries mensais de retornos de soja, café, milho e boi gordo no Brasil, identificando que essas *commodities* apresentam alta volatilidade e persistência de choques ao longo do tempo. Os modelos estimados indicam que os coeficientes α e β resultam em somas próximas ou maiores que um, o que sugere que os efeitos dos choques na volatilidade se prolongam por períodos significativos, impactando a renda dos agentes do setor agropecuário

Auriglietti & Tonin (2021) investigaram a influência da volatilidade dos preços e da liquidez do mercado sobre o comportamento da base em diferentes regiões de comercialização do café: Cerrado, Sul de Minas Gerais, Mogiana e Noroeste do Paraná. Os dados foram obtidos junto ao CEPEA e à B3, referentes ao período de 2002 a 2017. A análise indicou que choques de volatilidade no mercado futuro impactam negativamente a base, enquanto as variáveis de liquidez, apesar de estatisticamente significativas, apresentam menor influência sobre ela.

Mais recentemente, estudos vêm adotando técnicas de modelagem de séries temporais, como o ARIMA, para a previsão de preços da commodity milho. Tibulo & Carli (2014) compararam o desempenho do modelo ARIMA com o de Alisamento Exponencial de Holt-Winters na modelagem da série do preço médio mensal do milho no estado do Rio Grande do Sul, considerando o período de março de 2004 a fevereiro de 2014. Os dados foram extraídos da plataforma AGROLINK. Ambos os modelos mostraram-se adequados para a previsão de preços futuros, sendo úteis como suporte para decisões comerciais.

Cas (2018) analisou os preços médios do milho e seus retornos, com dados obtidos também na plataforma AGROLINK, no período de março de 2004 a março de 2016. A análise foi realizada utilizando os softwares Eviews 8.0 e Gretl. O modelo estimado, ARMA(1,2), apresentou resultados satisfatórios para projeções de preços da commodity. Todos os modelos avaliados mostraram-se eficazes na geração de projeções satisfatórias para o preço do milho no mercado brasileiro, demonstrando a relevância do uso de métodos de previsão para antecipar movimentos de mercado, o que traz benefícios significativos aos agentes do agronegócio (Cas, 2018).

Silva *et al.* (2023) aplicaram o modelo ARIMA(1,1,1) para prever os preços mensais do milho no estado do Mato Grosso, com base nos dados divulgados pela CONAB, abrangendo o período de janeiro de 2019 a fevereiro de 2023. A previsão foi realizada para quatro meses à frente da amostra, utilizando o software R. Os resultados indicaram bom desempenho do modelo ajustado.

Apesar da existência de alguns estudos voltados à previsão de preços ou à análise da base do milho, não foram encontrados trabalhos que se dedicaram à análise da base de preços do cereal no estado de Minas Gerais por meio da modelagem de séries temporais. Essa lacuna reforça a relevância e a originalidade da presente proposta de pesquisa.

3 METODOLOGIA

3.1 O conjunto de dados

A variável de estudo neste trabalho refere-se à base de milho. Os dados foram calculados considerando os preços do produto em mercados físicos de Minas Gerais e os preços diários na Bolsa, Balcão - B3. As praças físicas consideradas foram Iraí de Minas, Unaí, Noroeste de Minas, Oeste de Minas, Sudoeste de Minas e Triângulo Mineiro, conforme apresentado na Figura 3.1.

Os dados dos mercados físicos foram extraídos para o período de 16/07/2018 a 31/12/2024 da plataforma *Broadcast*, que é uma plataforma privada de dados que propaga informações financeiras no país. O acesso a esses dados foi concedido pela empresa JPA Agro, que é uma empresa de compra e venda de produtos agrícolas como máquinas, produtos de nutrição animal, insumos, etc. localizada na cidade de Lavras - Minas Gerais. Já a série da B3 para o mesmo período de análise foi extraída do *website* INVESTING.COM (2023), considerando o ativo relacionado ao contrato contínuo. Os dados da variável de interesse (bases) foram calculados pela diferença entre o preço na praça física e na B3.

Figura 3.1 – Distribuição das praças de comércio de milho pelo Estado de Minas Gerais.



Fonte: Próprio autor via *R*.

3.2 Análise e Ajuste dos Modelos para as Bases

Os procedimentos de análise de dados foram realizados por meio do *software R*, utilizando uma combinação de pacotes especializados em séries temporais, modelagem estatística e diagnóstico de modelos. O processo teve início com a análise exploratória da série temporal em estudo, a partir da qual foram obtidas estatísticas descritivas essenciais, como média, desvio padrão, assimetria e curtose, que permitiram uma compreensão inicial do comportamento da série ao longo do tempo.

Em seguida, foram investigadas possíveis estruturas de tendência e sazonalidade, complementadas por testes formais de estacionariedade, como o teste de Dickey-Fuller Aumentado (ADF) e Phillips-Perron (PP), ambos com a hipótese nula de presença de raiz unitária, a rejeição dessa hipótese indica que a série é estacionária. A verificação da estacionariedade é uma etapa fundamental, pois determina a necessidade de diferenciação da série antes da aplicação de modelos autorregressivos, como o AR.

A análise prosseguiu com o exame das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), que são ferramentas diagnósticas importantes para identificar a presença de dependência temporal e indicar os possíveis valores dos parâmetros autorregressivos (AR) e de média móvel (MA) que compõem a estrutura do modelo. Com base nessa análise, foi possível propor uma estrutura inicial para o modelo, que foi então ajustado à série.

Após o ajuste do modelo AR, foi realizada uma avaliação do comportamento dos resíduos por meio de gráficos de correlogramas. Um bom ajuste é indicado pela ausência de autocorrelação nos resíduos, que devem se comportar como um Ruído Branco, ou seja, apresentar distribuição aproximadamente normal, com média nula, variância constante e ausência de autocorrelação significativa. A constatação desses padrões sinaliza que o modelo conseguiu capturar adequadamente a estrutura de dependência temporal dos dados.

Entretanto, para investigar a possível presença de heterocedasticidade condicional – característica comum em séries financeiras – procedeu-se à análise dos resíduos ao quadrado e também da aplicação do teste Multiplicador de Lagrange para Modelos ARCH (teste ARCH-LM) que é usado para verificar a heterocedasticidade condicional em séries temporais. A detecção de padrões de volatilidade indicou a necessidade de incorporar um modelo GARCH, que permite modelar a variância condicional da série ao longo do tempo. Após o ajuste do modelo GARCH, foram repetidas as etapas de diagnóstico dos resíduos, com o objetivo de verificar se o novo modelo eliminava a heterocedasticidade residual, garantindo a adequação do ajuste.

Com os modelos ajustados e validados, foram então realizadas previsões para um horizonte de 7 e 15 dias. Para isso, a série foi dividida em dois subconjuntos: um conjunto de treinamento, que compreendeu todas as observações até o ponto anterior ao início da previsão, e um conjunto de teste, formado pelas últimas 7 e 15 observações. Esse procedimento de separação dos dados permite avaliar a capacidade preditiva dos modelos em dados não utilizados no ajuste, conferindo maior robustez à análise.

Os testes estatísticos utilizados para verificar as propriedades das séries temporais, bem como as análises dos resíduos dos modelos ajustados, foram realizados ao longo do processo de modelagem. Os resultados detalhados desses testes, incluindo gráficos de resíduos, testes de autocorrelação e heterocedasticidade, encontram-se disponíveis nos anexos deste trabalho.

De forma prática, os modelos utilizados permitem avaliar o mercado de milho com mais clareza. Para os produtores e vendedores, as previsões de base mostram quando: o mercado físico tende a ficar mais valorizado que o futuro, indicando bons momentos para vender; o

mercado físico está mais pressionado, indicando maior oferta e possibilidade de estoque ou venda futura.

Já para os compradores, como indústrias de ração e laticínios, entender o comportamento da base ajuda a: programar compras em períodos de maior vantagem; reduzir custos com aquisição de matéria-prima; organizar contratos de *hedge* e travamentos de preço com menor risco.

Ao mesmo tempo, o estudo da volatilidade revela o quanto as oscilações são intensas e persistentes, permitindo que ambos os lados se preparem para movimentos abruptos — que são comuns no mercado agrícola.

3.2.1 Recursos Computacionais Utilizados

Para a realização das análises estatísticas e modelagem das séries temporais, foram utilizados diversos pacotes da linguagem R, cada um com funcionalidades específicas que contribuam para as diferentes etapas do estudo.

A importação dos dados foi realizada através do uso do pacote *readxl*, que permite a leitura de arquivos no formato Excel (.xls e .xlsx) de forma prática e eficiente. Esse pacote é especialmente útil em contextos corporativos ou acadêmicos, onde os dados geralmente são organizados em planilhas eletrônicas.

O pacote *rugarch* foi empregado para a modelagem da volatilidade condicional, por meio da classe de modelos GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*). Esse pacote fornece uma estrutura robusta para estimação, simulação e previsão de modelos GARCH e suas variantes, como EGARCH, GJR-GARCH e APARCH, permitindo ainda a escolha entre diferentes distribuições para os resíduos, como normal, t-Student e skewed-t. É amplamente utilizado em aplicações financeiras, dada sua capacidade de capturar a heterocedasticidade presente nos retornos de ativos.

Para a manipulação e estruturação dos dados temporais, utilizou-se o pacote *xts* (*eXtensible Time Series*), que fornece uma classe de objetos voltada para séries temporais indexadas por datas. Com ele, foi possível organizar os dados em uma estrutura adequada para análise, além de realizar operações como agregações, extração de janelas temporais, e alinhamento de séries.

Durante a análise exploratória, o pacote *eI071* foi utilizado para calcular medidas estatísticas importantes, como a assimetria (*skewness*) e a curtose (*kurtosis*) das distribuições.

O pacote *tseries* também teve um papel importante, oferecendo uma série de testes estatísticos essenciais para a análise de séries temporais. Entre eles, destacam-se o teste de Dickey-Fuller aumentado (ADF), utilizado para verificação da estacionariedade da série, e os testes de autocorrelação. Além disso, o pacote fornece implementações básicas de modelos ARIMA, úteis para análises iniciais e comparativas.

Para a etapa de previsão, foi empregado o pacote *forecast*, que é amplamente reconhecido por sua eficiência e simplicidade no ajuste de modelos e ETS (*Exponential Smoothing*). O pacote também permite a geração de previsões com intervalos de confiança e facilita a comparação entre diferentes modelos.

Por fim, o pacote *FinTS* foi utilizado para realizar testes de diagnóstico nos resíduos dos modelos ajustados, com destaque para o teste ARCH-LM, que verifica a presença de heterocedasticidade condicional. Essa etapa é fundamental para validar a adequação dos modelos GARCH, uma vez que a ausência de autocorrelação e heterocedasticidade nos resíduos é um dos principais critérios para a aceitação do modelo.

Esses procedimentos foram realizados separadamente para cada praça e os resultados são apresentados na seção seguinte.

4 ANÁLISE DOS RESULTADOS

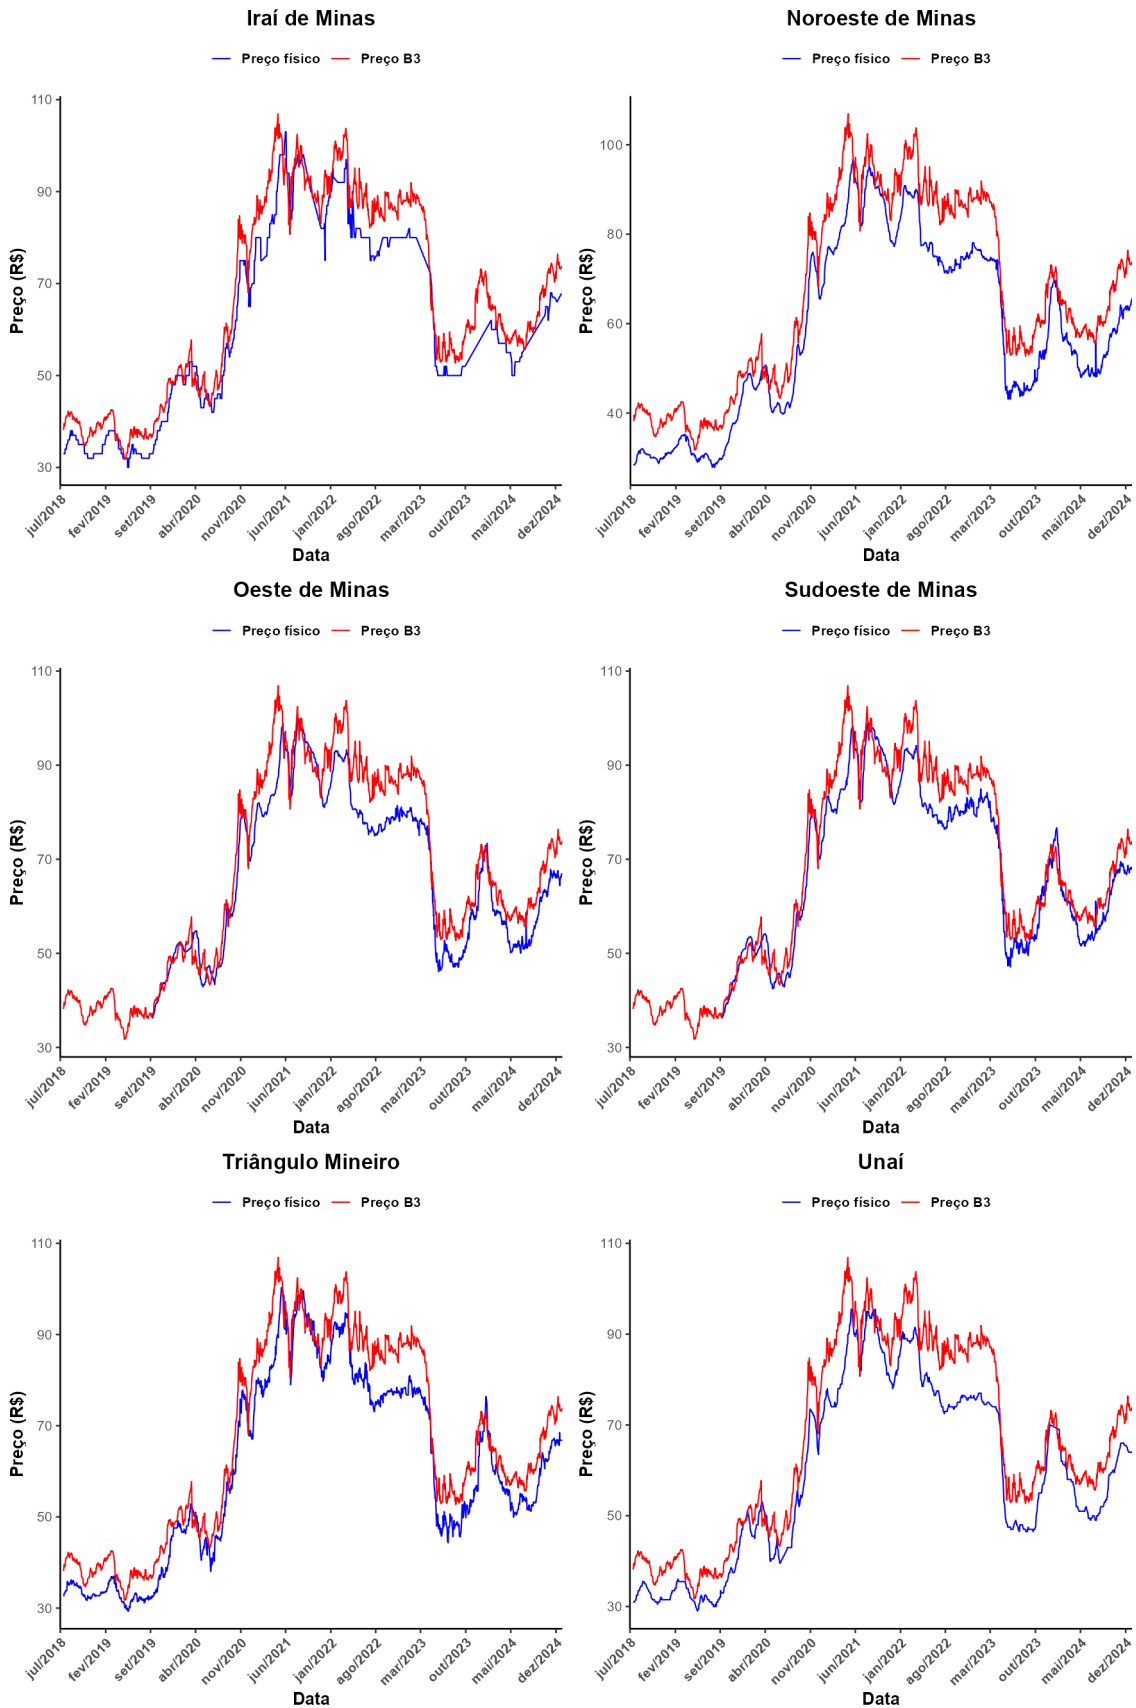
4.1 Análise exploratória dos dados

Para calcular as bases, foram utilizados dados diários (com frequência de 5 dias úteis) extraídos da plataforma *Broadcast*, abrangendo o período de 16 de julho de 2018 a 31 de dezembro de 2024. Esse intervalo foi escolhido por oferecer uma série histórica suficientemente longa para captar diferentes cenários de mercado, o que proporciona uma análise mais robusta.

Os dados do mercado futuro referem-se aos preços da B3, que servem como referência nacional para a comercialização do milho. Já os dados do mercado físico correspondem às cotações praticadas em seis importantes praças regionais de Minas Gerais: Iraí, Noroeste, Oeste, Sudoeste, Triângulo e Unai.

A Figura 4.1 ilustra a comparação entre os preços futuros (B3) e os preços físicos de cada praça. Essa visualização permite observar, de maneira clara, como os mercados locais se alinham com o comportamento da B3, ao mesmo tempo em que revela as diferenças estruturais entre os preços, que podem acontecer por vários motivos, como o custo para transportar o milho, a distância até os compradores, a quantidade de milho disponível em cada região, a qualidade do produto e a época da colheita

Figura 4.1 – Série histórica dos preços de milho nas praças físicas de Minas Gerais acompanhados da Série Histórica da B3.



Fonte: Próprio autor via R.

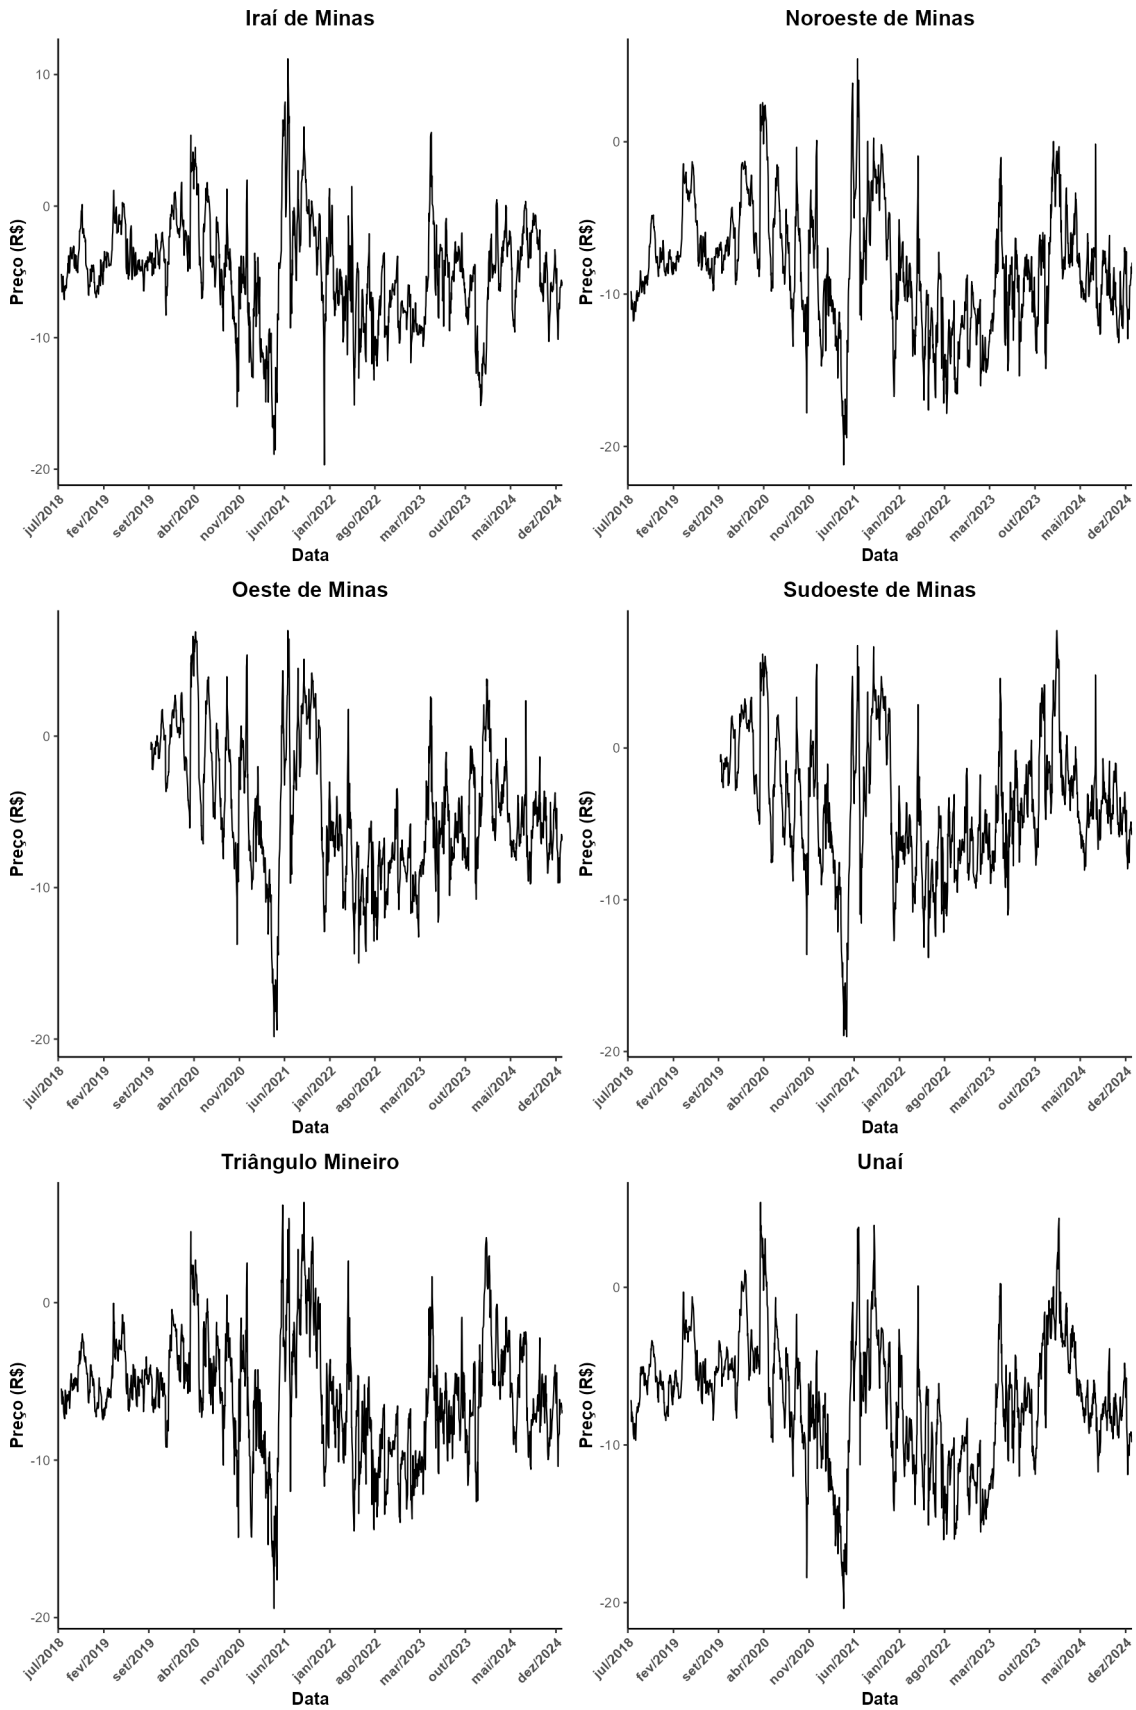
Analisando a Figura 4.1 temos seis gráficos de séries temporais, cada um comparando os preços da B3 com os preços das diferentes praças regionais do mercado de milho em Minas Gerais. A linha azul representa os preços da B3, enquanto a vermelha representa o preço local da respectiva praça.

Os gráficos revelam que os preços das praças regionais analisadas mantêm uma forte associação com os preços da B3, confirmando a relevância do mercado futuro como referência de preços no mercado físico. Ainda assim, a diferença nas trajetórias das bases sugere a importância de modelá-lo individualmente para cada região.

De modo geral, observa-se que os preços nas praças locais acompanham bem a movimentação do mercado futuro. Quando há alta ou queda na B3, os mercados regionais reagem de forma semelhante. Esse comportamento indica uma forte correlação entre os preços futuros e os preços físicos, mostrando que o mercado futuro atua como referência para a formação de preços nas diferentes regiões.

Mesmo com esse alinhamento, é possível notar uma diferença constante entre as curvas, em que os preços da B3 tendem a ser mais altos do que os das praças locais. Essa diferença, conhecida como base, pode ser explicada por fatores como custos de transporte, armazenagem, demanda local, entre outros aspectos regionais. Embora o tamanho do base varie conforme a praça, o padrão de comportamento é semelhante entre elas. Os gráficos apresentados na Figura 4.2 evidenciam que o base não é estável ao longo do tempo nas principais praças analisadas em Minas Gerais.

Figura 4.2 – Base de Milho para as principais praças de comercialização de MG para o período de julho de 2018 a dezembro de 2024.



Fonte: Próprio autor via R.

Apesar das diferenças entre as praças, é possível notar um padrão comum: a base tende a se estreitar com valores mais próximos de zero em certos períodos, e se alargar com valores mais negativos em outros momentos. Essa leitura reforça a ideia de que conhecer seu comportamento ao longo do tempo pode auxiliar produtores e agentes do mercado na escolha do melhor momento para travar preços ou adotar mecanismos de proteção, sendo uma estratégia essencial para o processo de comercialização.

As estatísticas descritivas referentes aos dados das bases de preço de milho das diferentes praças de comercialização de milho em Minas Gerais estão apresentadas na Tabela 4.1. Esses indicadores fornecem uma visão inicial sobre o comportamento das séries analisadas ao longo do período estudado.

Tabela 4.1 – Estatísticas descritivas das praças de comércio de milho de Minas Gerais.

Praças	Mínimo	Média	Máximo	Desvio-padrão	Assimetria	Curtose	CV
Iraí de Minas	-19,670	-4,982	11,200	3,909	-0,055	0,931	78,455
Noroeste de Minas	-21,210	-8,313	5,450	3,944	0,188	1,151	47,442
Oeste de Minas	-19,840	-4,949	6,970	4,522	0,144	-0,122	91,380
Sudoeste de Minas	-19,020	-3,778	7,740	4,257	-0,024	0,271	112,673
Triângulo Mineiro	-19,420	-5,759	6,370	3,712	0,083	0,405	64,463
Unaí	-20,370	-7,130	5,390	3,916	-0,111	0,217	54,938

Fonte: Próprio autor via R.

Ao analisar os resultados das estatísticas descritivas obtidos para as diferentes praças, observa-se que a praça que apresentou maior dispersão em termos absolutos, medida pelo desvio-padrão, foi a do Oeste de Minas, com um valor de 4,522. Isso indica que os dados dessa região variam mais amplamente em relação à sua média quando comparados às demais praças.

Por outro lado, a praça que apresentou o maior coeficiente de variação foi a Sudoeste de Minas, com 112,673%. Esse indicador mostra que, proporcionalmente à média, essa praça tem a maior variabilidade relativa, ou seja, os dados são mais heterogêneos em relação ao seu valor médio.

Em contraste, o Noroeste de Minas apresentou o menor coeficiente de variação (47,442%), indicando uma maior homogeneidade dos seus dados em relação à média, apesar de ter um desvio-padrão relativamente alto.

Quanto à assimetria, todas as praças mostraram valores próximos de zero, indicando distribuições quase simétricas dos dados. Entretanto, o Sudoeste de Minas apresentou a assimetria negativa (-0,024), sugerindo uma leve tendência. Já o Noroeste de Minas mostrou a maior assimetria positiva (0,18), indicando uma leve concentração de valores maiores.

Em relação à curtose, que avalia a concentração dos dados nas caudas da distribuição, o Noroeste de Minas destacou-se com um valor positivo de 1,151, indicando uma maior presença de valores extremos (caudas mais pesadas) nessa região. As demais praças apresentaram valores próximos a zero, sugerindo distribuições mais próximas da normalidade.

Em resumo, embora a Oeste de Minas tenha a maior dispersão absoluta, a Sudoeste de Minas é a praça com maior variabilidade relativa dos dados. Já o Noroeste de Minas apresenta dados relativamente mais homogêneos, mas com maior tendência a valores extremos.

Analisando os resultados dos testes de estacionariedade disponibilizados na Tabela 4.2, observa-se que as estatísticas ADF indicam que todas as praças, exceto o Sudoeste de Minas, apresentaram valores significativos ao nível de 10%, sugerindo que as séries temporais dessas regiões são estacionárias, ou seja, não possuem raiz unitária e suas propriedades estatísticas são constantes ao longo do tempo.

Tabela 4.2 – Estatísticas dos Testes de Raiz Unitária.

Estatísticas	Iraí de Minas	Noroeste	Oeste	Sudoeste	Triângulo Mineiro	Unai
ADF	-5,436*	-5,894*	-5,313*	-5,255	-5,862*	-4,863*
PP	-91,005*	-80,607*	-64,994*	-68,426	-95,729*	-65,213*

Fonte: Próprio autor via R.

Nota: *** significante ao nível de 1%; ** significante ao nível de 5%; * significante ao nível de 10%.

Quanto ao teste PP (Tabela 4.2), os valores para todas as praças, exceto Sudoeste, foram significativos, o que reforça a conclusão de que as séries temporais analisadas são estacionárias. Destaca-se que o Iraí de Minas apresentou o maior valor absoluto no teste PP (-91.005).

Logo, tanto o teste ADF quanto o PP confirmam a estacionariedade das séries temporais para todas as praças analisadas, o que é fundamental para garantir a validade de modelagens e análises que dependem dessa condição. Isso é importante porque a estacionariedade é uma condição necessária para a aplicação dos modelos AR, garantindo resultados e previsões mais consistentes.

4.2 O Modelo AR

Com a confirmação da estacionariedade das séries, foi possível aplicar a modelagem AR, esse tipo de modelo é utilizado na análise de séries temporais pois consegue capturar os padrões de dependência temporal, combinando componentes autorregressivos, de médias móveis e, quando necessário, de diferenciação para tornar a série estacionária. A seguir, foram ajustados modelos AR para cada uma das praças, com o objetivo de analisar o comportamento da base e realizar previsões.

Ao analisar os resultados do Teste de Ljung-Box para as diferentes praças apresentados na Tabela 4.3, observa-se que todos os valores p são superiores a 0,05, variando entre 0,142 (Triângulo Mineiro) e 0,459 (Oeste de Minas). Isso indica que não há evidências suficientes para rejeitar a hipótese nula de ausência de autocorrelação nos resíduos em nenhum dos casos.

Tabela 4.3 – Modelos AR selecionados e resultados do Teste de Ljung-Box para os resíduos (valores p).

Praça	AR	Valores p
Iraí de Minas	(1, 0, 0)	0,246
Noroeste de Minas	(1, 0, 0)	0,347
Oeste de Minas	(1, 0, 0)	0,459
Sudoeste de Minas	(1, 0, 0)	0,253
Triângulo Mineiro	(1, 0, 0)	0,142
Unai	(2, 0, 0)	0,319

Fonte: Próprio autor via R.

Esse resultado sugere que os resíduos dos modelos ou séries temporais analisadas se comportam como ruído branco, ou seja, são independentes e não apresentam padrão sistemático ao longo do tempo. A presença de resíduos como ruído branco é desejável, pois significa que o modelo capturou bem a estrutura dos dados, e o que sobra é apenas variação aleatória sem autocorrelação.

Portanto, os resultados do Box Test (Tabela 4.3) indicam que os modelos ajustados para todas as praças apresentam resíduos independentes, reforçando a adequação dos modelos e a segurança das análises realizadas.

Os resultados do Teste ARCH-LM (Tabela 4.4) indicam que todas as praças apresentam heterocedasticidade condicional, ou seja, a variância dos erros não é constante ao longo do

tempo, mas varia de forma dependente de seus próprios valores passados. Essa característica é típica de séries financeiras e econômicas que exibem períodos de maior e menor volatilidade.

Tabela 4.4 – Teste ARCH LM.

Praça	Estatística	valor p
Iraí de Minas	128,61	<0,001
Noroeste	142,76	<0,001
Oeste	122,89	<0,001
Sudoeste	129,39	<0,001
Triângulo Mineiro	56,06	<0,001
Unaí	144,32	<0,001

Fonte: Próprio autor via R.

Dessa forma, o próximo passo é a implementação de um modelo GARCH, pois esse tipo de modelo é desenvolvido para capturar e modelar essa variabilidade condicional da variância, permitindo que se descreva de forma mais precisa o comportamento da volatilidade ao longo do tempo.

4.3 O Modelo GARCH

A adoção do modelo GARCH possibilita uma melhor adequação aos dados, além de fornecer previsões mais realistas da volatilidade futura, essenciais para análise de risco, tomada de decisão e outras aplicações.

Portanto, considerando a presença de heterocedasticidade confirmada pelo teste ARCH-LM, a implementação do modelo GARCH é um passo fundamental para analisar as séries de base nas praças em estudo.

A seguir, foram ajustados modelos GARCH para cada uma das praças, com o objetivo de analisar a volatilidade da base e realizar previsões, considerando a presença de heterocedasticidade nas séries temporais. Esses modelos são adequados para capturar variações ao longo do tempo, comuns em dados econômicos e financeiros.

A implementação dos modelos GARCH para as diferentes praças analisadas mostrou características do comportamento da volatilidade ao longo do tempo como observa-se na Ta-

bela 4.5. Um dos principais destaques é a alta persistência da volatilidade observada em praças como Iraí de Minas, Noroeste de Minas, Unaí e Triângulo Mineiro. Nessas regiões, a soma dos coeficientes ARCH (α) e GARCH (β) se aproxima ou ultrapassa 0,99, indicando que choques ocorridos em determinado período continuam influenciando a volatilidade por vários períodos subsequentes. Por outro lado, as praças de Oeste de Minas e Sudoeste de Minas também apresentaram modelos GARCH significativos, porém com menor persistência da volatilidade.

Tabela 4.5 – Parâmetros Estimados do Modelo GARCH considerando as diferentes praças físicas de Minas Gerais.

Praças	μ	ϕ_1	ω	α_1	β_1	ν
Iraí de Minas	0,026	0,144 ***	0,029 *	0,112 ***	0,887 ***	2,954 ***
Noroeste de Minas	0,039 **	0,119 ***	0,022 **	0,135 ***	0,863 ***	3,295 ***
Oeste de Minas	0,014	0,101 ***	0,203 **	0,282 ***	0,672 ***	3,107 ***
Sudoeste de Minas	0,024	0,105 ***	0,248 **	0,282 ***	0,635 ***	3,307 ***
Triângulo Mineiro	0,023	0,078 **	0,005	0,059 ***	0,939 ***	4,034 ***
Unaí	0,026 *	0,075 ***	0,022 **	0,128 ***	0,870 ***	3,195 ***

Fonte: Próprio autor via R.

Nota: *** significante ao nível de 1%; ** significante ao nível de 5%; * significante ao nível de 10%.

Outro ponto relevante refere-se ao parâmetro ν , que controla o grau de caudas pesadas da distribuição. Os valores de ν ficaram acima de 3, indicando que as séries apresentam maior propensão a valores extremos do que o esperado em uma distribuição normal. Isso reforça a necessidade de modelos robustos, como o GARCH com distribuição t ou t-generalizada, que captam adequadamente esses comportamentos extremos. Por esse motivo, a escolha de distribuições t nos modelos GARCH foi apropriada, permitindo capturar esse risco com mais eficácia.

Além disso, os coeficientes ϕ_1 também se mostraram significativos, indicando a presença de autocorrelação na média das séries — o que justifica o uso de modelos ARMA-GARCH para representar a dinâmica conjunta da média e da variância.

Após o ajuste dos modelos de séries temporais aos dados da base do milho nas diferentes praças de comercialização em Minas Gerais, foram realizadas as previsões dos modelos. Essa etapa tem como objetivo avaliar a capacidade preditiva dos modelos selecionados, considerando o comportamento futuro da série com base em suas características históricas. As previsões

permitem analisar o desempenho dos modelos ajustados, sendo fundamentais para a tomada de decisões estratégicas e a gestão de riscos de base.

Os resultados obtidos com o modelo GARCH mostram que a volatilidade da base do milho em Minas Gerais é persistente, ou seja, quando ocorre um choque — como uma queda brusca no mercado futuro ou um aumento inesperado na oferta — seus efeitos tendem a durar vários períodos. Na prática, isso significa que: os preços não voltam rapidamente à estabilidade, os riscos permanecem elevados por mais tempo e a incerteza aumenta para quem precisa decidir se compra ou vende.

Para produtores, isso sinaliza a necessidade de maior cautela nas decisões de venda, podendo levar à adoção de estratégias de *hedge* mais prolongadas. Para compradores, como indústrias e cooperativas, essa persistência reforça a importância de acompanhar o comportamento do mercado futuro e ajustar contratos de fornecimento com mais frequência.

4.4 Os modelos preditivos para as bases de preços nas principais praças de Minas Gerais

As previsões foram realizadas para o período de 7 dias e 15 dias, com o objetivo de avaliar o desempenho dos modelos em cada praça permitindo observar seus comportamentos. Para avaliar a qualidade das previsões, foram utilizadas métricas estatísticas como o Erro Absoluto Médio (MAE), o Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio (MAPE), que fornecem informações para comparar o desempenho entre os modelos aplicados às diferentes praças.

Os gráficos apresentados nas Figuras 4.3 - 4.14 mostram os resultados obtidos para cada período de previsão, possibilitando a análise entre os valores observados e preditos.

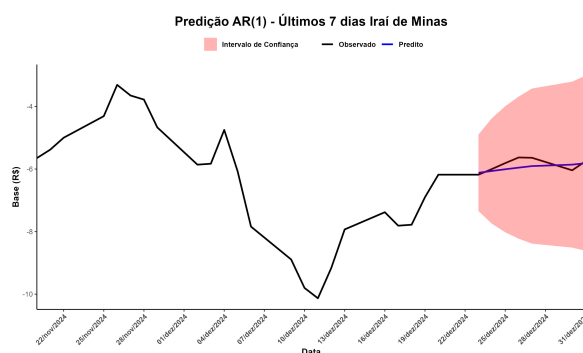


Figura 4.3 – Predição 7 dias – Iraí de Minas




Figura 4.4 – Predição 15 dias – Iraí de Minas

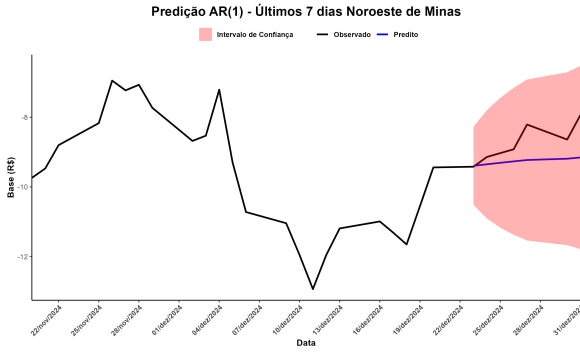


Figura 4.5 – Predição 7 dias – Noroeste de Minas




Figura 4.6 – Predição 15 dias – Noroeste de Minas

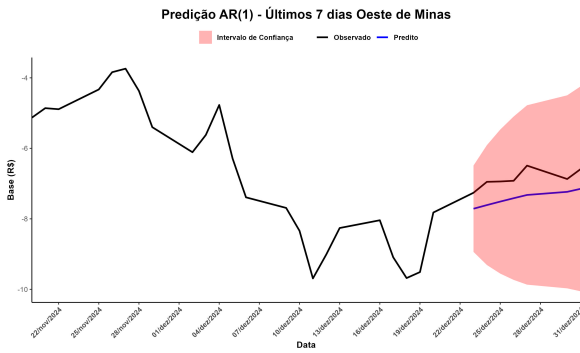


Figura 4.7 – Predição 7 dias – Oeste de Minas

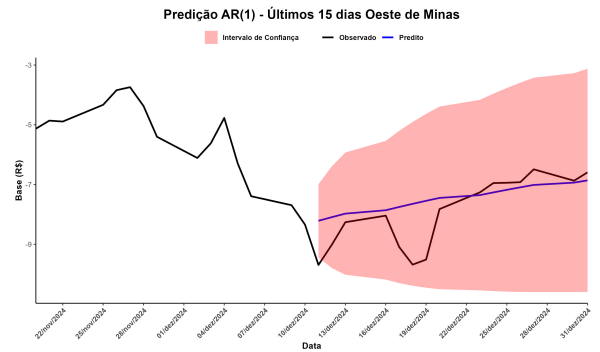


Figura 4.8 – Predição 15 dias – Oeste de Minas

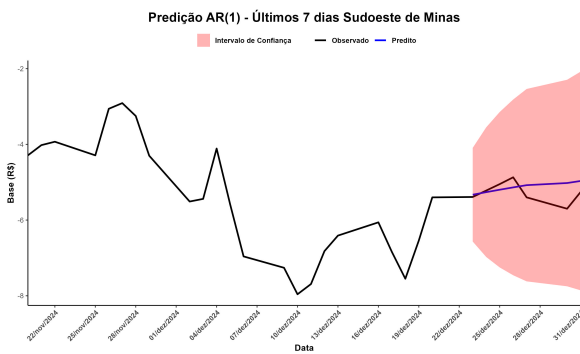


Figura 4.9 – Predição 7 dias – Sudoeste de Minas

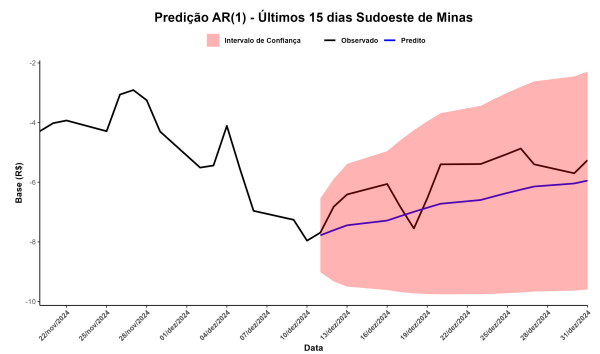


Figura 4.10 – Predição 15 dias – Sudoeste de Minas



Figura 4.11 – Predição 7 dias – Triângulo Mineiro

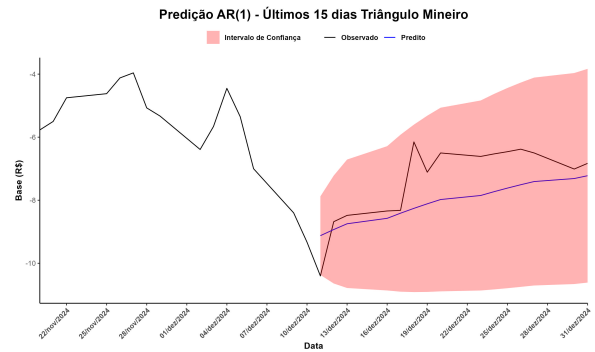


Figura 4.12 – Predição 15 dias – Triângulo Mineiro

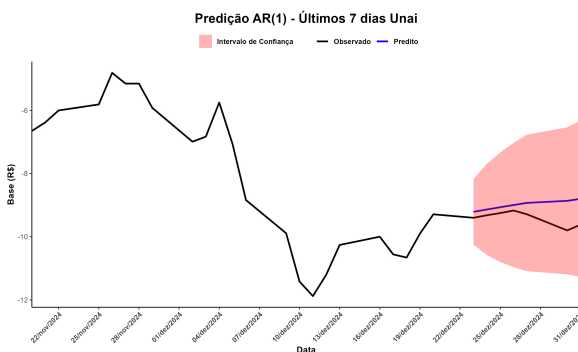


Figura 4.13 – Predição 7 dias – Unai

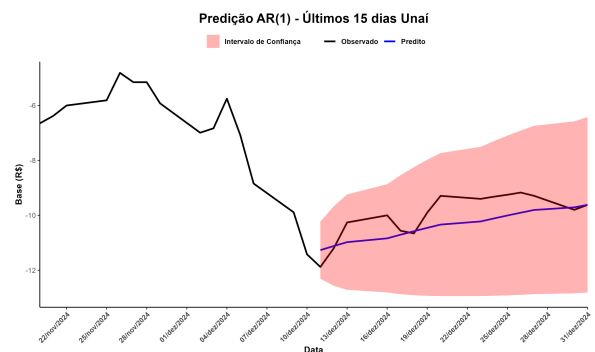


Figura 4.14 – Predição 15 dias – Unai

Fonte: Próprio autor via R.

De modo geral, os modelos conseguiram capturar a tendência das séries até o ponto de corte, seguindo o padrão observado sem apresentar oscilações abruptas ou desvios significativos. As faixas de incerteza representadas pela área sombreada aumentam ao longo do horizonte de previsão, o que é esperado em modelos de séries temporais, refletindo o crescimento natural da incerteza em valores mais distantes no tempo.

As previsões de 7 e 15 dias fornecem uma ferramenta prática para quem precisa planejar a compra e venda de milho em curto prazo. Produtores podem usar essas previsões para escolher semanas mais favoráveis para comercializar sua produção, decidir entre vender imediatamente ou armazenar, avaliar a oportunidade de realizar hedge na B3. Indústrias, cooperativas e compradores podem usar para antecipar períodos de maior custo, programar estoques de maneira mais eficiente e otimizar contratos de entrega e frete.

Embora a previsão seja de curto prazo, ela é extremamente útil no mercado agrícola, em que uma semana pode representar variação significativa no preço final da negociação. A partir da visualização dos gráficos e das análises das métricas apresentadas na Tabela 4.6 podemos

observar que as previsões para o curto prazo (7 dias) mostram-se mais precisas, com intervalos de confiança mais estreitos e maior proximidade entre os valores estimados e os valores reais. Já para o período de 15 dias, a maioria das projeções ainda permanece dentro de limites aceitáveis, mostrando um bom ajuste dos modelos mesmo em prazos mais longos.

Tabela 4.6 – Parâmetros de Predição.

Praças	Métricas	15 dias	7 dias
Iraí	MAE	1,378	0,165
	RMSE	1,482	0,192
	MAPE	21,65 %	2,86 %
Noroeste	MAE	1,138	0,522
	RMSE	1,344	0,663
	MAPE	12,43 %	6,25 %
Oeste	MAE	0,683	0,562
	RMSE	0,953	0,579
	MAPE	7,81 %	8,24 %
Sudoeste	MAE	0,837	0,259
	RMSE	0,939	0,327
	MAPE	14,91 %	4,83 %
Triângulo	MAE	0,868	0,272
	RMSE	1,036	0,371
	MAPE	12,66 %	4,00 %
Unaí	MAE	0,509	0,407
	RMSE	0,617	0,509
	MAPE	5,35 %	4,26 %

Fonte: Próprio autor via R.

Os gráficos de desvio padrão condicional estimado pelos modelos GARCH (Figuras 4.15 a 4.20) para as diferentes praças de comercialização de milho em Minas Gerais apresentados anteriormente mostram padrões consistentes de comportamento da volatilidade ao longo do tempo. Observa-se a ocorrência de picos agudos de volatilidade, os quais indicam momentos de maior incerteza no mercado, possivelmente associados a choques como variações climáticas, mudanças na oferta e demanda, ou instabilidades macroeconômicas.

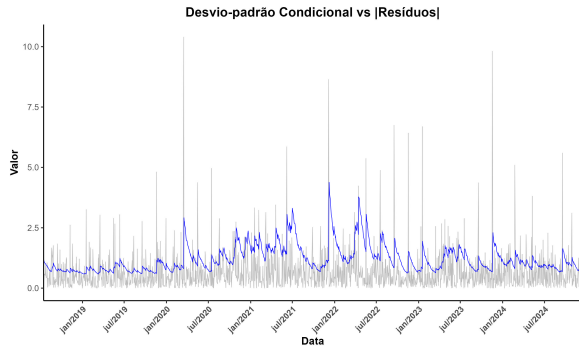


Figura 4.15 – Desvio Padrão Condicional do modelo GARCH da praça de Iraí




Figura 4.16 – Desvio Padrão Condicional do modelo GARCH da praça de Noroeste

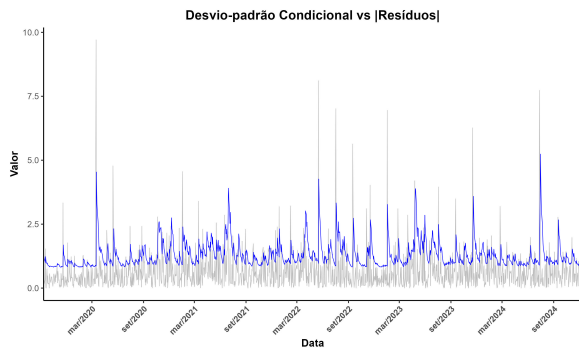


Figura 4.17 – Desvio Padrão Condicional do modelo GARCH da praça de Oeste




Figura 4.18 – Desvio Padrão Condicional do modelo GARCH da praça de Sudoeste




Figura 4.19 – Desvio Padrão Condicional do modelo GARCH da praça de Triângulo Mineiro




Figura 4.20 – Desvio Padrão Condicional do modelo GARCH da praça de Unaí

Fonte: Próprio autor via *R*.

Um aspecto recorrente em todas as séries é a presença de *clusters* de volatilidade, ou seja, períodos de alta volatilidade tendem a ser seguidos por novos períodos igualmente instáveis, característica típica de processos heterocedásticos. Esse comportamento indica que os

choques de mercado possuem efeitos persistentes, impactando a variância dos retornos por intervalos prolongados.

Apesar de variações na intensidade e frequência dos picos de volatilidade entre as diferentes regiões (por exemplo, picos mais frequentes em Iraí e Sudoeste), o padrão geral é semelhante, com o modelo GARCH mostrando-se eficaz em capturar a estrutura temporal da variância condicional. A linha azul, que representa a volatilidade estimada, ajusta-se bem aos retornos absolutos (em cinza), evidenciando que o modelo é adequado para descrever a dinâmica da volatilidade dos preços.

Os gráficos apresentados nas Figuras 4.21 a 4.26 correspondem à volatilidade condicional estimada pelos modelos GARCH para cada uma das regiões analisadas, com base nos retornos das séries temporais dos preços da base de milho. Esses retornos, representados pelas linhas azuis, indicam as variações percentuais diárias nos preços, enquanto as linhas vermelhas delimitam os intervalos de confiança associados à volatilidade estimada.




Figura 4.21 – Volatilidade Condicional do modelo GARCH da praça de Iraí

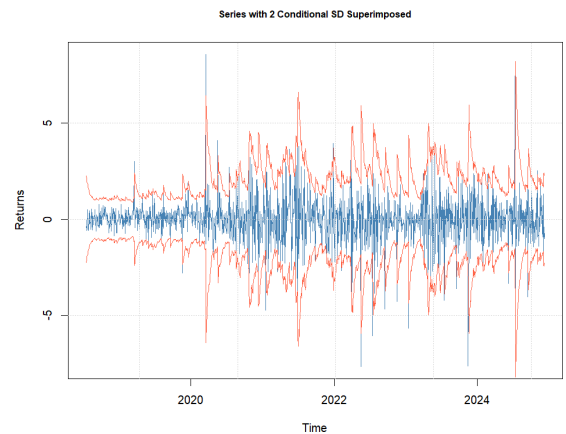


Figura 4.22 – Volatilidade Condicional do modelo GARCH da praça do Noroeste

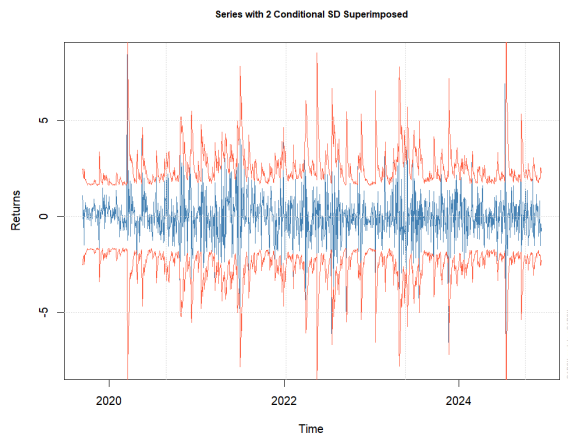


Figura 4.23 – Volatilidade Condicional do modelo GARCH da praça de Oeste

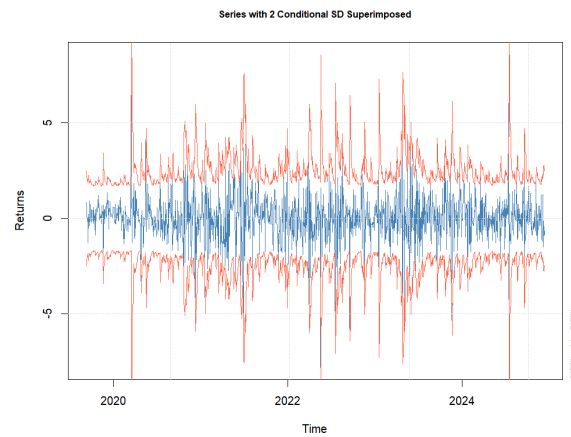


Figura 4.24 – Volatilidade Condicional do modelo GARCH da praça de Sudoeste




Figura 4.25 – Volatilidade Condicional do modelo GARCH da praça do Triângulo Mineiro

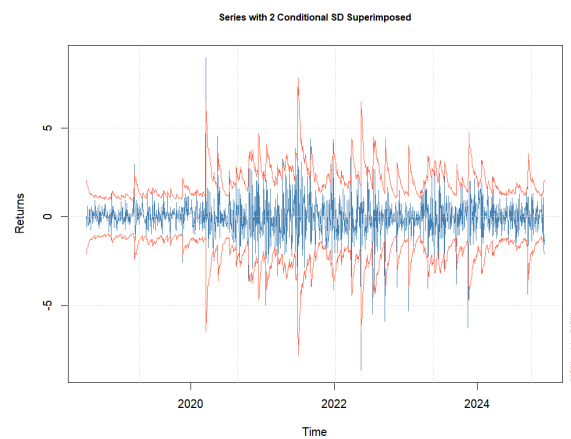


Figura 4.26 – Volatilidade Condicional do modelo GARCH da praça de Unaí

Fonte: Próprio autor via *R*.

Essa análise permite inferir diferenças no comportamento do risco de preço entre as praças, o que pode estar associado a fatores como estrutura de mercado, volume de negociação e integração com o mercado futuro.

De forma geral, os resultados reforçam a necessidade de incorporar a heterocedasticidade nos modelos de análise e previsão para séries de preços agrícolas, contribuindo para uma melhor avaliação de riscos e tomada de decisões por parte de produtores, comerciantes e formuladores de políticas públicas.

A modelagem GARCH aplicada às diferentes praças forneceu uma leitura sobre o comportamento da volatilidade ao longo do tempo em cada região. De maneira geral, os modelos se mostraram adequados e mostraram padrões distintos de variação condicional.

O estudo contribui para diminuir uma das principais dificuldades do mercado de milho em Minas Gerais: a incerteza sobre a relação entre preços físicos e futuros. Ao mostrar como a base se comporta nas diferentes regiões e quão volátil ela é, torna-se possível ajustar estratégias regionais de venda, negociar contratos com maior embasamento, reduzir perdas por falta de informação, fortalecer a participação dos produtores no mercado futuro e facilitar decisões diárias de compra e venda.

5 CONSIDERAÇÕES FINAIS

Os resultados obtidos demonstraram que os modelos considerados foram adequados para capturar, respectivamente, a estrutura de dependência temporal e a volatilidade condicional da base de preços do milho das diversas praças em Minas Gerais. A análise dos dados diários, abrangendo o período de 2018 a 2024, permitiu observar as dinâmicas tanto do comportamento dos preços quanto da volatilidade, fatores essenciais para o entendimento e gestão dos riscos de negociação dessa *commodity*. Na prática, isso significa oferecer aos agentes do setor um instrumento de apoio à decisão, capaz de orientar negociações, identificar momentos mais vantajosos e reduzir a exposição ao risco, aumentando a segurança no processo de comercialização.

Para o produtor rural, os resultados oferecem uma ferramenta confiável para compreender oscilações de preços entre o mercado físico e o mercado futuro, permitindo avaliar com mais clareza os momentos mais adequados para travar preços, negociar contratos ou planejar o escoamento da produção. Para o mercado, a pesquisa auxilia na formação mais eficiente de preços e na compreensão das dinâmicas regionais da base, apoiando cooperativas, cerealistas, indústrias de ração e agentes de *hedge*.

A partir da abordagem proposta, foi possível obter previsões com bom desempenho e identificar comportamentos diferenciados entre as praças analisadas, revelando a potencialidade desses métodos estatísticos para apoiar decisões no âmbito comercial e financeiro do setor agropecuário.

As evidências de volatilidade persistente reforçam a necessidade de planejamento contínuo e monitoramento frequente do mercado. A modelagem da volatilidade ajuda a identificar períodos de maior instabilidade, melhorando o gerenciamento de risco e a previsibilidade das operações. Assim, o trabalho fortalece a conexão entre mercado físico e mercado futuro, promovendo maior transparência, eficiência e estabilidade nas negociações.

Já as predições de curto prazo se mostraram eficientes para auxiliar a rotina operacional de compra e venda, contribuindo para maior eficiência no uso de estoques, redução de custos e melhoria da lucratividade, tanto para quem produz quanto para quem compra.

Além disso, a comparação entre os modelos possibilitou identificar as características específicas de cada uma das praças mineiras, ressaltando a importância de considerar as particularidades regionais nas análises.

Portanto, os resultados indicam que a modelagem da base do preço do milho por meio de séries temporais é uma ferramenta importante para agentes do mercado, oferecendo informações necessárias para a maximização de receitas e a minimização de riscos tanto para compradores quanto para vendedores, pois as informações se convertem em benefícios concretos para o setor produtivo, fortalecendo a tomada de decisão e aproximando o produtor e a indústria de um mercado mais previsível e estratégico. Essa abordagem contribui para uma melhor compreensão do comportamento dos preços e da volatilidade, aspectos fundamentais para o desenvolvimento do mercado do agronegócio em Minas Gerais.

REFERÊNCIAS

- ARCE, R. de; MAHIA, R. Modelos arima. **Programa CITUS: Técnicas de Variables Financieras**, v. 5, 2003.
- AURIGLIETTI, L. M. de M.; TONIN, J. M. Relação entre base, volatilidade e liquidez: evidências para o mercado futuro de café no brasil. **Revista Estratégias e Soluções**, 2021.
- BARROS Áther de M.; AGUIAR, D. R. D. Gestão do risco de preço de café arábica: uma análise por meio do comportamento da base. **Revista de Economia e Sociologia Rural**, v. 43, p. 443–464, 2005.
- BRASIL. **Mercado de Derivativos no Brasil: Conceitos, Produtos e Operações**. Rio de Janeiro: BMFBovespa, 2015. v. 1. 118 p.
- CALDARELLI, C. E.; BACCHI, M. R. P. Fatores de influência no preço do milho no brasil. **Nova economia**, v. 22, p. 141–164, 2012.
- CAMPOS, K. C. Análise da volatilidade de preços de produtos agropecuários no brasil. **Revista de Economia e Agronegócio/Brazilian Review of Economics and Agribusiness**, v. 5, n. 3, p. 303–327, 2007.
- CAMPOS, K. C. Análise da volatilidade de preços de produtos agropecuários no brasil: soja, café, milho e boi gordo. **Revista de Economia e Agronegócio**, v. 5, n. 3, p. 421–442, 2007. Disponível em: https://repositorio.ufc.br/bitstream/riufc/4999/1/2007_eve_kccampos.pdf.
- CAS, C. G. Aplicação do modelo arima para previsão do preço da commodity milho. **Revista Gestão da Produção Operações e Sistemas**, v. 13, n. 1, p. 263–279, 2018.
- CONAB, C. N. D. A. Calendário de plantio e colheita de grãos no brasil 2022. Brasília, 2022.
- CONTINI, E. *et al.* Milho: caracterização e desafios tecnológicos. Embrapa,(Desafios do Agronegócio Brasileiro, 2), Brasília, 2019.
- CRUZ, J. C. *et al.* Cultivo do milho. **Embrapa Milho e Sorgo, Versão Eletrônica**, v. 6ª edição, 2010.
- CRUZ, M. A. da; MACEDO, M. A. da S. Mercados futuros de commodities agropecuárias. In: **XXII Encontro Nacional de Engenharia de Produção**. Curitiba/PR: [s.n.], 2002.
- EHLERS, R. S. **Análise de séries temporais**. Universidade Federal do Paraná: Laboratório de Estatística e Geoinformação, 2007. v. 1. 1-118 p.
- FILENI, D. H. **O RISCO DE BASE, A EFETIVIDADE DO HEDGING E UM MODELO PARA A ESTIMATIVA DA BASE: UMA CONTRIBUIÇÃO AO AGRONEGÓCIO DO CAFÉ EM MINAS GERAIS**. 137 p. Mestrado em Administração Rural — Universidade Federal de Lavras, Lavras - MG, 1999.
- FILENI, D. H.; MARQUES, P. V.; MACHADO, H. M. O risco de base e a efetividade do hedge para o agronegócio do café em minas gerais. **Revista de Administração da UFLA**, 1999.

- FONTES, R. E.; JUNIOR, L. G. de C.; AZEVEDO, A. F. Estratégia de comercialização em mercados derivativos-descobrimto de base e risco de base da cafeicultura em diversas localidades de minas gerais e são paulo. **Ciência e Agrotecnologia**, v. 29, n. 2, p. 382–389, 2005.
- GARCIA, J. C.; MATTOSO, M. J.; DUARTE, J. de O. Importância do milho em minas gerais. **Embrapa**, v. 27, n. 233, p. 7–12, 2006.
- INVESTING.COM. **Notícias do mercado financeiro**. 2023. <https://www.investing.com>. Acesso em: 18 jul. 2025.
- LOPES, L. P. Predição do preço do café naturais brasileiro por meio de modelos de statistical machine learning. **Sigmae**, v. 7, n. 1, p. 1–16, 2018.
- MASCARENHAS, K. **Conheça as principais variedades de milho usados na alimentação humana e animal**. 2021. Disponível em: <https://ufla.br/noticias/pesquisa/12714-conheca-as-principais-variedades-de-milho-usados-na-alimentacao-humana-e-animal>.
- MORETTIN, P. A.; TOLOI, C. M. de C. **Análise de séries Temporais**. São Paulo: Edgard Blucher, 2006.
- NARDINO, F. P.; FIGUEIREDO, A. M. R. "risco da base e sua volatilidade no comércio de soja em mato grosso (2009 a 2019)". **Revista de economia e sociologia**, v. 60, n. 1, p. e240267, 2021.
- NETO, O. J. de O.; BARBOSA, J. da S. La producción científica brasileña sobre hedge de precios agropecuarios: un estudio bibliométrico. **Estudios Rurales**, v. 14, n. 30, 2024.
- PEREIRA, L. G. R.; ANTUNES, R. C. O milho na alimentação de gado de leite. In: **IV SIMPÓSIO MINEIRO DE NUTRIÇÃO DE GADO DE LEITE**. Belo Horizonte/MG: [s.n.], 2007.
- REVISTAAGROPECUARIA. **Silagem de milho: Uma alternativa para nutrir o rebanho**. 2019. Disponível em: <https://www.revistaagropecuaria.com.br/2019/11/11/silagem-de-milho-uma-alternativa-para-nutrir-o-rebanho/>.
- SANCHES, A. L. R.; BARROS, G. S. de C.; ALVES, L. R. A. Contrato futuro de base de preços de milho no brasil: Evidências empíricas de transmissão assimétrica entre as regiões. In: **56° Congresso SOBER**. Campinas/SP: [s.n.], 2018.
- SCHELER, E. D.; CAVICHIOLI, F. A. Viabilidade de silagem de milho para o gado leiteiro. **Interface Tecnológica**, v. 18, n. 1, 2021.
- SILVA, A. C. d. **Modelagem da volatilidade condicional incorporando o efeito overnight ao Ibovespa futuro**. Dissertação (Dissertação de Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2021. Disponível em: <https://repositorio.ufmg.br/bitstream/1843/42188/2/Modelagem%20da%20Volatilidade%20Condicional%20Incorporando%20o%20Efeito%20Overnight%20ao.pdf>.
- SILVA, F. M. da *et al.* Liquidez dos contratos futuros de milho negociados na bmfbovespa. **Revista de Administração e Negócios da Amazônia**, v. 9, n. 1, p. 26–44, 2017.

SILVA, G. J. C. da; SOUZA, E. C.; MARTINS, H. E. de P. Produção agropecuária em municípios de minas gerais (1996-2006): padrões de distribuição, especialização e associação espacial. **Revista de Economia e Sociologia Rural**, v. 50, n. 2, p. 333–349, 2012.

SILVA, R. B. Z. da *et al.* Uso do modelo arima para previsão do preço do milho pago aos produtores no estado de mato grosso. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 10, n. 1, 2023.

SOARES, R. C. M. *et al.* Agronegócio: Influências da produção sazonal. In: **XI Congresso Brasileiro de Custos**. Porto Seguro/BA: [s.n.], 2004.

SOUSA, A. M. de *et al.* Comportamento dos preços de milho e feijão caupi no mercado do estado do ceará. **Verde de Agroecologia e Desenvolvimento Sustentável**, v. 10, n. 5, p. 16, 2015.

TIBULO, C.; CARLI, V. de. Previsão do preço do milho, através de séries temporais. **Scientia Plena**, v. 10, n. 10, 2014.

TONIN, J. M.; ALVES, A. F. Análise de base para o milho na região de maringá. **Revista Cesumar–Ciências Humanas e Sociais Aplicadas**, v. 12, n. 1, 2007.

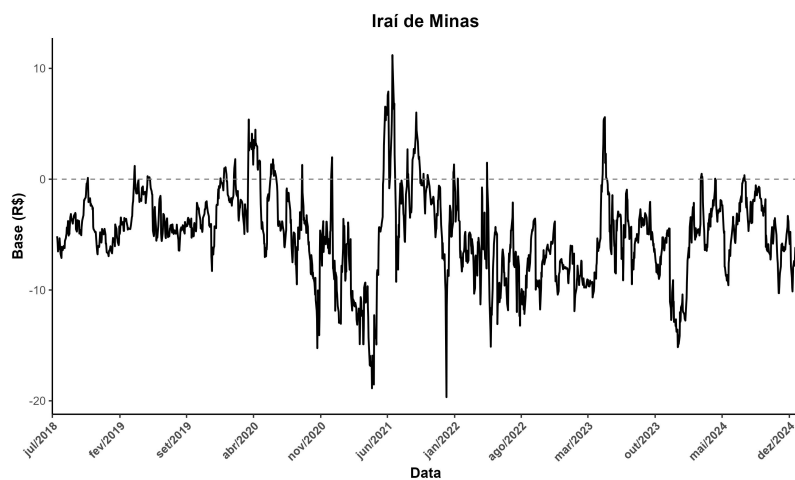
TONIN, J. M.; BRAGA, M. J.; COELHO, A. B. Efetividade de hedge do milho com contratos futuros da bmf: uma aplicação para a região de maringá (pr). **Revista de Economia**, v. 35, n. 1, 2009.

ANEXOS

ANEXO A – ANÁLISE DOS RESÍDUOS DO MERCADO DE IRAÍ DE MINAS

Foi analisada a série da base do milho (Figura 1), calculada como a diferença entre os preços no mercado físico de Iraí de Minas e no mercado futuro (B3), no período de 2018 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.

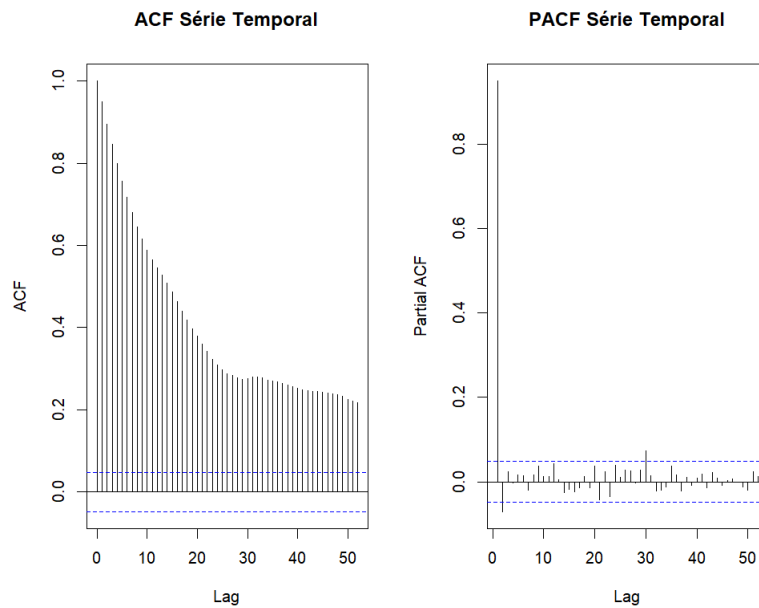
Figura 1 – Serie histórica da base de milho de Iraí de Minas.



Fonte: Próprio autor via R

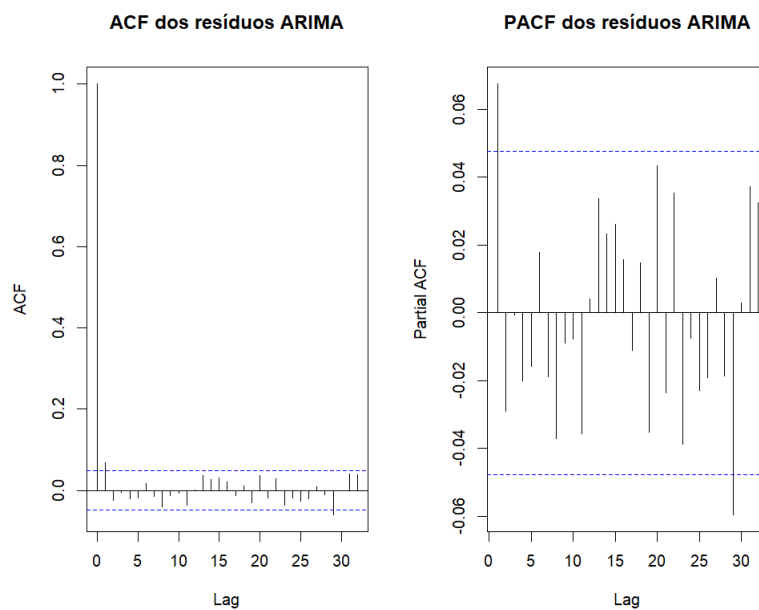
A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 2 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 3), confirmado pelo teste de Ljung-Box (p-valor = 0,246), indicando que os resíduos se comportam como ruído branco.

Figura 2 – ACF e PACF da base de Iraí.



Fonte: Próprio autor via *R*

Figura 3 – ACF e PACF dos resíduos do Modelo AR para a base de Iraí.

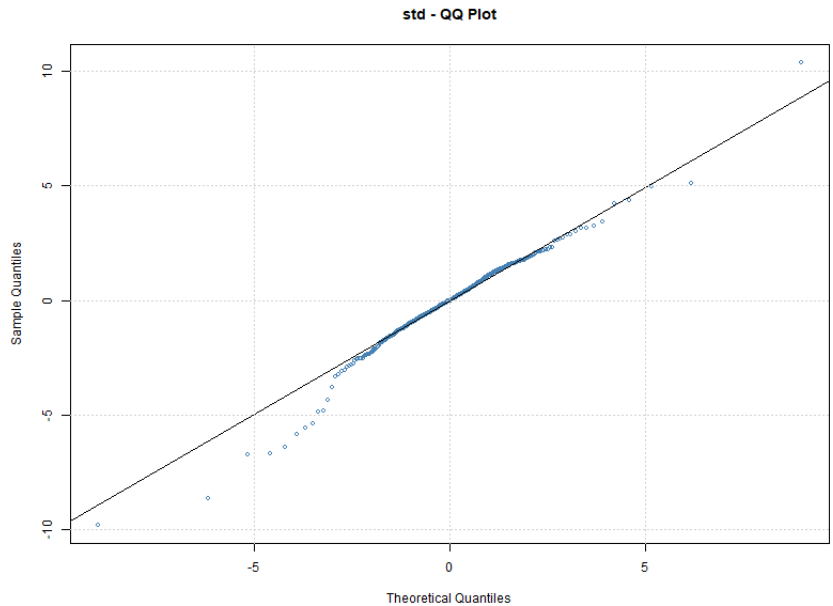


Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 4). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo.

Figura 4 – QQ-Plot dos Resíduos Padronizados da base de Iraí.



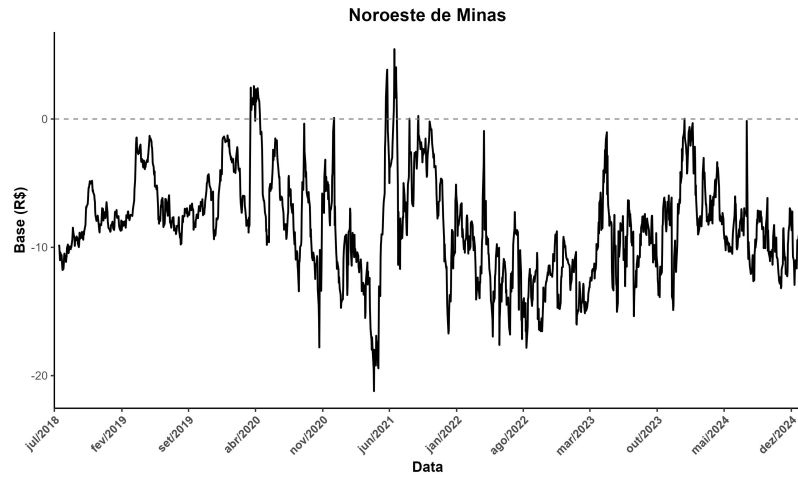
Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.

ANEXO B – ANÁLISE DOS RESÍDUOS DO MERCADO DE NOROESTE DE MINAS

Foi analisada a série da base do milho (Figura 5), calculada como a diferença entre os preços no mercado físico de Noroeste de Minas e no mercado futuro (B3), no período de 2018 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.


Figura 5 – Serie histórica da base de milho do Noroeste de Minas.



Fonte: Próprio autor via *R*


A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 6 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 7), confirmado pelo teste de Ljung-Box (p -valor = 0,088), indicando que os resíduos se comportam como ruído branco.

Figura 6 – ACF e PACF da base do Noroeste.



Fonte: Próprio autor via *R*

Figura 7 – ACF e PACF dos resíduos do Modelo AR para a base do Noroeste.




Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 8). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo, refletindo o aumento natural da incerteza.

Figura 8 – QQ-Plot dos Resíduos Padronizados da base do Noroeste.



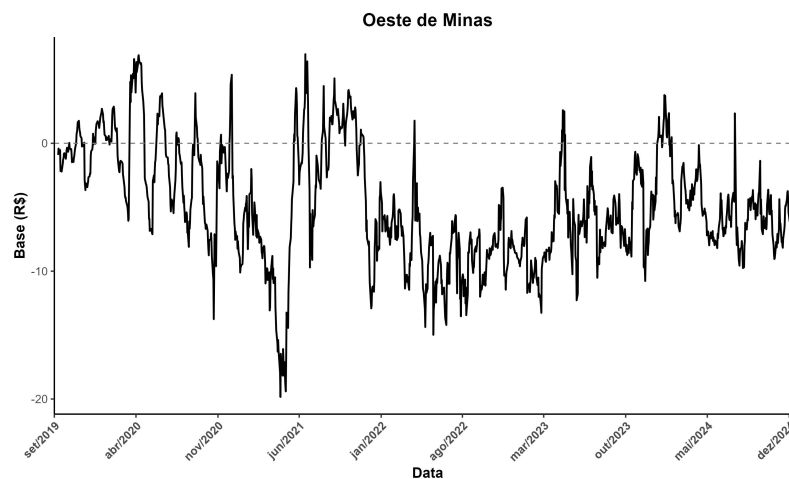
Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.

ANEXO C – ANÁLISE DOS RESÍDUOS DO MERCADO DO OESTE DE MINAS

Foi analisada a série da base do milho (Figura 9), calculada como a diferença entre os preços no mercado físico de Oeste de Minas e no mercado futuro (B3), no período de 2019 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.

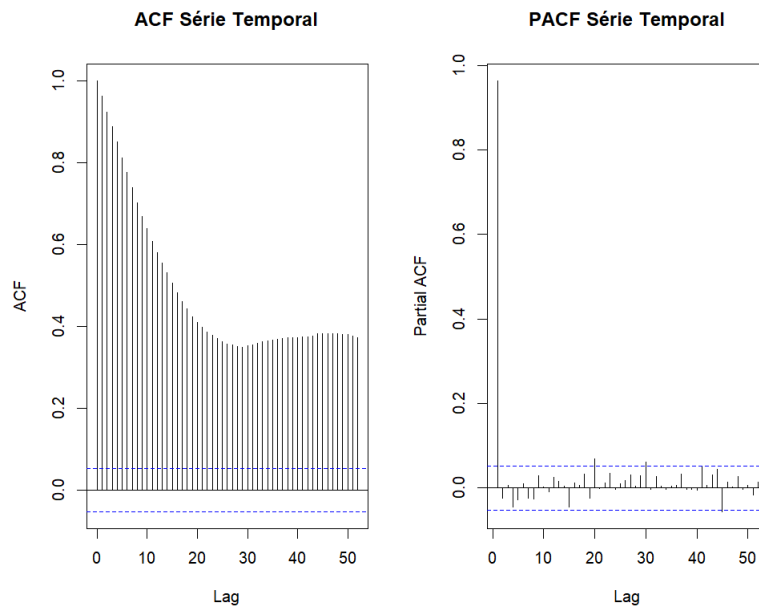
Figura 9 – Serie histórica da base de milho do Oeste de Minas.



Fonte: Próprio autor via *R*


A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 10 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 11), confirmado pelo teste de Ljung-Box (p-valor = 0,088), indicando que os resíduos se comportam como ruído branco.

Figura 10 – ACF e PACF da base do Oeste de Minas.



Fonte: Próprio autor via *R*

Figura 11 – ACF e PACF dos resíduos do Modelo AR para a base do Oeste de Minas.




Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 12). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo, refletindo o aumento natural da incerteza.

Figura 12 – QQ-Plot dos Resíduos Padronizados da base do Oeste de Minas.



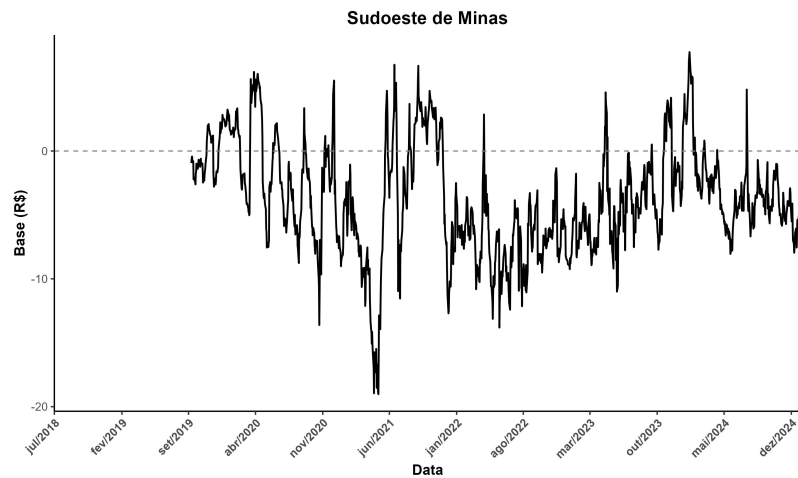
Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.

ANEXO D – ANÁLISE DOS RESÍDUOS DO MERCADO DO SUDOESTE DE MINAS

Foi analisada a série da base do milho (Figura 13), calculada como a diferença entre os preços no mercado físico do Sudoeste de Minas e no mercado futuro (B3), no período de 2019 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.


Figura 13 – Série histórica da base de milho do Sudoeste de Minas.



Fonte: Próprio autor via *R*


A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 14 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 15), confirmado pelo teste de Ljung-Box (p -valor = 0,088), indicando que os resíduos se comportam como ruído branco.

Figura 14 – ACF e PACF da base do Sudoeste Mineiro.



Fonte: Próprio autor via *R*

Figura 15 – ACF e PACF dos resíduos do Modelo AR para a base do Sudoeste Mineiro.

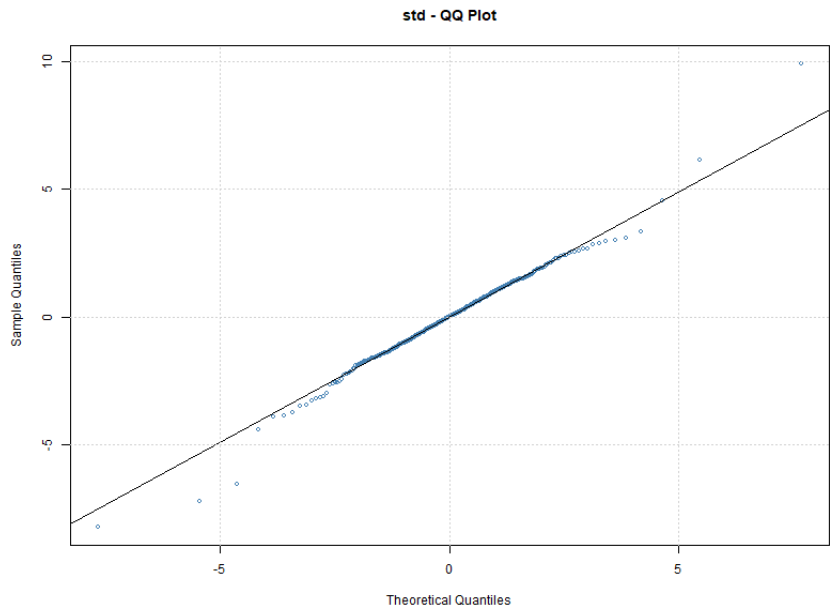


Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 16). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo, refletindo o aumento natural da incerteza.

Figura 16 – QQ-Plot dos Resíduos Padronizados da base do Sudoeste Mineiro.



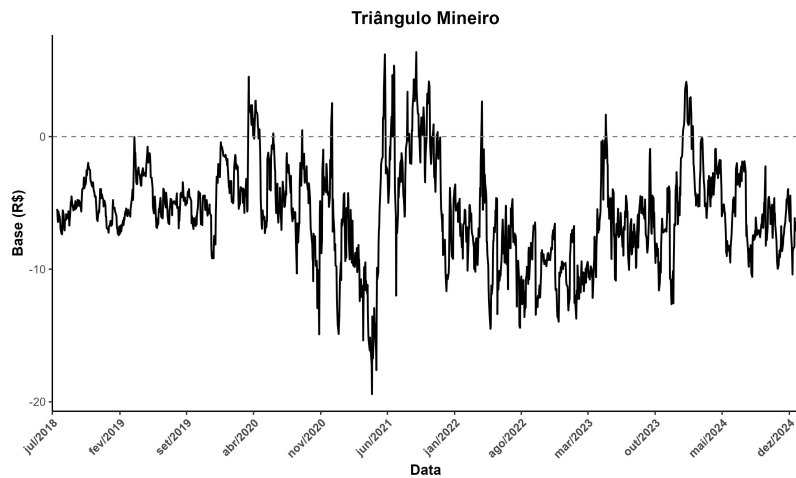
Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.

ANEXO E – ANÁLISE DOS RESÍDUOS DO MERCADO DO TRIÂNGULO MINEIRO

Foi analisada a série da base do milho (Figura 17), calculada como a diferença entre os preços no mercado físico do Triângulo Mineiro e no mercado futuro (B3), no período de 2019 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.

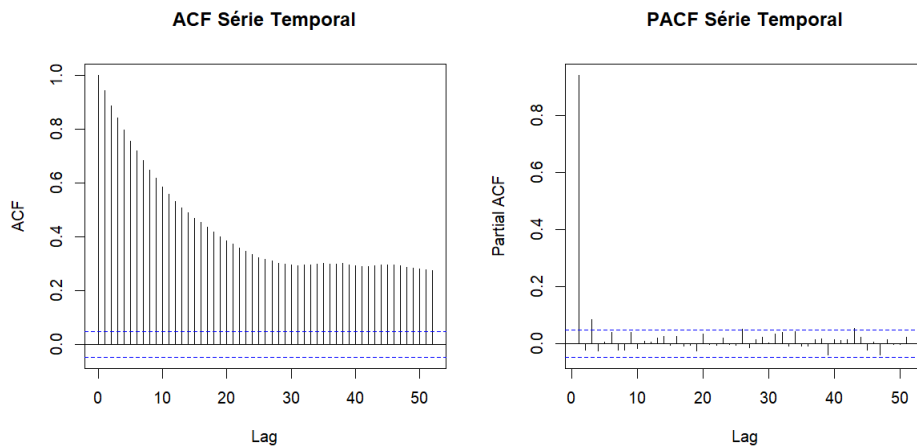
Figura 17 – Serie histórica da base de milho do Triângulo Mineiro.



Fonte: Próprio autor via *R*

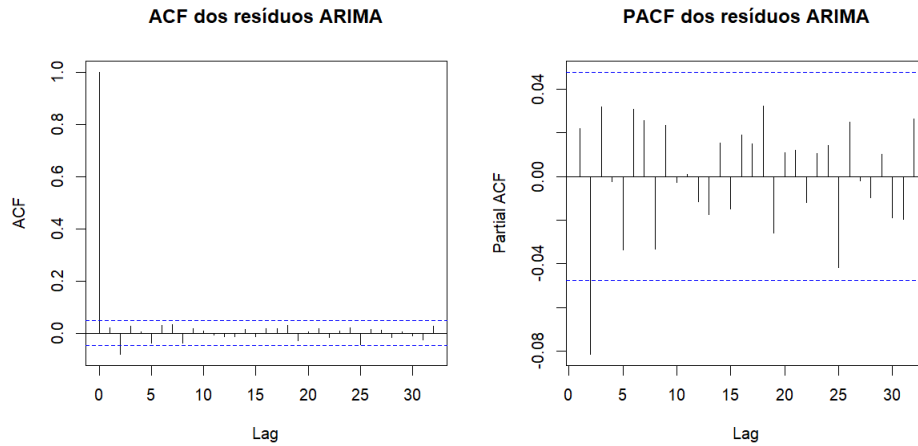
A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 18 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 19), confirmado pelo teste de Ljung-Box (p-valor = 0,088), indicando que os resíduos se comportam como ruído branco.

Figura 18 – ACF e PACF da base do Triângulo Mineiro.



Fonte: Próprio autor via *R*

Figura 19 – ACF e PACF dos resíduos do Modelo AR para a base do Triângulo Mineiro.




Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 20). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo, refletindo o aumento natural da incerteza.

Figura 20 – QQ-Plot dos Resíduos Padronizados da base do Triângulo Mineiro.




Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.

ANEXO F – ANÁLISE DOS RESÍDUOS DO MERCADO DE UNAÍ

Foi analisada a série da base do milho (Figura 21), calculada como a diferença entre os preços no mercado físico de Unaí e no mercado futuro (B3), no período de 2019 a 2024. Os testes de estacionariedade (ADF e PP) confirmaram que a série é estacionária, permitindo o uso do modelo AR.

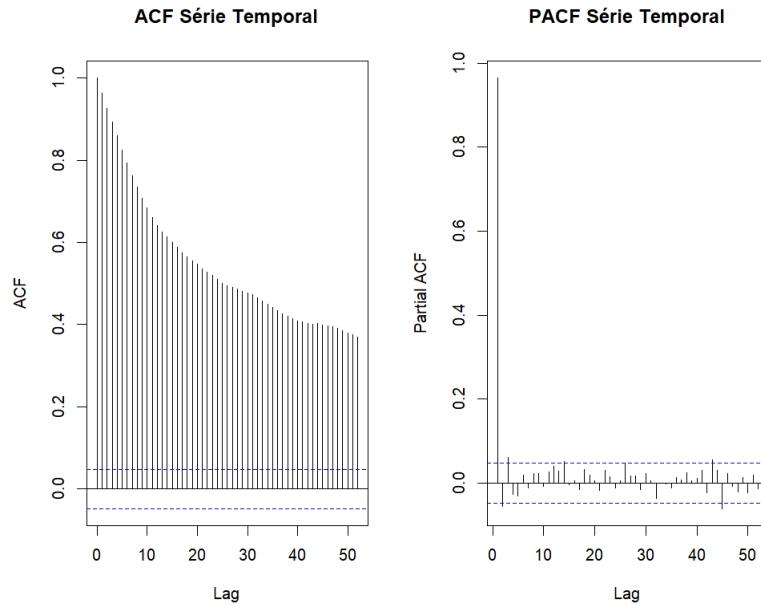
Figura 21 – Serie histórica da base de milho do Triângulo Mineiro.



Fonte: Próprio autor via *R*


A análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) observadas na Figura 22 indicou a escolha do modelo AR(1). Os resíduos do modelo não apresentaram autocorrelação significativa (Figura 23), confirmado pelo teste de Ljung-Box (p-valor = 0,088), indicando que os resíduos se comportam como ruído branco.

Figura 22 – ACF e PACF da base de Unai



Fonte: Próprio autor via *R*

Figura 23 – ACF e PACF dos resíduos do Modelo AR para a base de Unai.




Fonte: Próprio autor via *R*

O teste ARCH indicou a presença de heterocedasticidade, o que levou ao ajuste de um modelo GARCH(1,1) para capturar a volatilidade condicional. A volatilidade estimada pelo modelo apresentou características típicas de séries financeiras, com períodos alternados de maior e menor volatilidade.

O QQ-Plot dos resíduos padronizados sugeriu normalidade aproximada (Figura 24). As previsões feitas com o modelo GARCH apresentaram faixas de confiança crescentes ao longo do tempo, refletindo o aumento natural da incerteza.

Figura 24 – QQ-Plot dos Resíduos Padronizados da base de Unai.



Fonte: Próprio autor via *R*

Conclui-se que o modelo AR foi adequado para capturar a estrutura temporal da base, enquanto o modelo GARCH melhorou a modelagem da volatilidade, fornecendo previsões consistentes e robustas para a série analisada.