



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO DE ENGENHARIA DE PRODUÇÃO MECÂNICA

Igor Augusto Obreli Mouco

**Impacto das Variáveis Climáticas no Preço do Café Arábica no Espírito Santo:
Uma Análise de Séries Temporais**

Florianópolis

2024

Igor Augusto Obreli Mouco

**Impacto das Variáveis Climáticas no Preço do Café Arábica no Espírito Santo:
Uma Análise de Séries Temporais**

Trabalho Conclusão do Curso de Graduação em Engenharia de Produção Mecânica do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Engenharia, área Mecânica, habilitação em Engenharia de Produção Mecânica.

Orientador: Prof. Daniel Christian Henrique, Dr.

Florianópolis

2024

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Mouco, Igor Augusto Obreli
Impacto das Variáveis Climáticas no Preço do Café
Arábica no Espírito Santo: Uma Análise de Séries Temporais
/ Igor Augusto Obreli Mouco ; orientador, Daniel Christian
Henrique, 2024.
72 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro
Tecnológico, Graduação em Engenharia de Produção Mecânica,
Florianópolis, 2024.

Inclui referências.

1. Engenharia de Produção Mecânica. 2. Preço do Café.
3. Séries Temporais. 4. Vetores Autorregressivos. 5.
Variáveis Climáticas. I. Henrique, Daniel Christian. II.
Universidade Federal de Santa Catarina. Graduação em
Engenharia de Produção Mecânica. III. Título.

Igor Augusto Obreli Mouco

**Impacto das Variáveis Climáticas no Preço do Café Arábica no Espírito Santo:
Uma Análise de Séries Temporais**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de “Engenheiro Mecânico com habilitação em Engenharia de Produção” e aprovado em sua forma final pelo Curso de Engenharia de Produção Mecânica.

Florianópolis, 20 de dezembro de 2024.



Coordenação do Curso

Banca examinadora



Prof. Daniel Christian Henrique, Dr.

Orientador

Florianópolis, 2024.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me conceder sabedoria, paciência e força para alcançar meus objetivos. Por colocar em meu caminho pessoas incríveis que me ajudaram e tornaram minha caminhada mais leve, mesmo nos momentos mais desafiadores.

À minha mãe, Josiane, que nunca deixou de acreditar em mim e sempre me apoiou para que eu continuasse estudando e perseguindo meus sonhos. Ao Algacir, que, desde a minha infância, assumiu o papel de pai e me deu todo o suporte necessário para me tornar quem sou hoje. Vocês são e sempre serão fundamentais na minha trajetória. Obrigado por tudo.

A todos os meus familiares, que sempre torceram por mim e, mesmo à distância, enviaram energias positivas e me desejaram sucesso em cada etapa.

Aos amigos que conquistei durante a graduação, que foram parte essencial do meu desenvolvimento. Agradeço pelas trocas de experiências, pelos conselhos, pelo apoio nos momentos difíceis e por tornarem meus dias mais felizes, mesmo diante dos desafios.

Ao meu orientador, Prof. Dr. Daniel Christian Henrique, pela paciência e dedicação em me auxiliar neste trabalho, especialmente em um momento difícil para mim. Sua orientação foi indispensável para a conclusão desta etapa.

Ao PET Engenharia de Produção da UFSC, que me proporcionou a oportunidade de me redescobrir e evoluir como pessoa e como profissional. Esse grupo se tornou uma família para mim e desempenhou um papel essencial na minha jornada acadêmica. Em especial, agradeço à professora Mirna de Borba e ao professor Antonio Cezar Bornia, tutores que sempre estiveram presentes e dispostos a auxiliar no meu desenvolvimento.

A todos os professores e servidores da Universidade Federal de Santa Catarina que, de alguma forma, contribuíram para que eu chegasse até aqui. Levarei comigo essa experiência na UFSC com muito carinho e gratidão.

E, finalmente, a todos que, de alguma forma, fizeram parte desse ciclo universitário. Meu sincero muito obrigado.

RESUMO

Este trabalho tem como objetivo analisar o impacto das variáveis climáticas no preço do café arábica no estado do Espírito Santo, utilizando dados de 2018 a 2022. A pesquisa adota uma abordagem quantitativa e utiliza técnicas de modelagem de análise de séries temporais, como Vetores Autoregressivos (VAR), decomposição da variância e Função Impulso-Resposta, para identificar a relação entre as variáveis climáticas e o preço do café. A análise revelou que variáveis como precipitação, pressão atmosférica e radiação não têm impacto significativo sobre o preço do café. Em contrapartida, a temperatura de bulbo e a temperatura de orvalho mostraram-se variáveis com forte impacto, especialmente em defasagens temporais de 1 a 6 meses. A decomposição da variância indicou que a temperatura de bulbo, principalmente com 3 defasagens, explica uma porção relevante da variação do preço e a temperatura de orvalho também, quando defasada em um período. A pesquisa contribui para um melhor entendimento dos fatores climáticos que afetam o mercado de café, oferecendo informações valiosas para produtores e gestores do setor, que podem utilizar esses dados para aprimorar o planejamento de safras e estratégias de comercialização.

Palavras-chave: Preço do Café; Variáveis Climáticas; Séries Temporais; Vetores Autorregressivos; Regressão Linear.

ABSTRACT

This study aims to analyze the impact of climatic variables on the price of Arabica coffee in the state of Espírito Santo, using data from 2018 to 2022. The research adopts a quantitative approach and employs time series modeling techniques, such as Vector Autoregressive (VAR), variance decomposition, and Impulse Response Function, to identify the relationship between climatic variables and coffee prices. The analysis revealed that variables such as precipitation, atmospheric pressure, and radiation have no significant impact on coffee prices. Conversely, wet-bulb temperature and dew point temperature showed a strong impact, especially with time lags of 1 to 6 months. Variance decomposition indicated that wet-bulb temperature, particularly with 3 lags, explains a significant portion of price variation, while dew point temperature also plays a role when lagged by one period. The research contributes to a better understanding of the climatic factors affecting the coffee market, providing valuable insights for producers and industry managers, who can use this data to enhance crop planning and marketing strategies.

Keywords: Coffee Price; Climatic Variables; Time Series; Autoregressive Vectors, Linear Regression.

LISTA DE FIGURAS

Figura 1 - Produção e Exportações Brasileiras no Ranking Mundial em 2020.....	18
Figura 2 - Climas do Brasil.	21
Figura 3 - Etapas realizadas do trabalho.....	30
Figura 4 - Série Temporal de Preço da Saca de Café.....	34
Figura 5 - Teste ADF para a Série Temporal do Preço do Café.....	35
Figura 6 - Teste KPSS para a Série Temporal do Preço do Café.	35
Figura 7 - Série Temporal de Preço da Saca de Café.....	36
Figura 8 - Série Temporal Precipitação.	37
Figura 9 - Série Temporal do Preço com a Precipitação.	38
Figura 10 - Série Temporal do Preço com a Pressão.	41
Figura 11 - Série Temporal do Preço com a Radiação.....	43
Figura 12 - Série Temporal do Preço e Temp. de Bulbo.	46
Figura 13 - FIR: Preço vs Temperatura de Bulbo Seco (lag 3).....	51
Figura 14 - Série Temporal do Preço com a Temp. de Orvalho.	52
Figura 15 - FIR: Preço vs Temperatura de Orvalho (lag 1).	55
Figura 16 - Série Temporal do Preço com a Umidade.	57
Figura 17 - Série Temporal do Preço com o Vento.	59
Figura 18 - FIR: Preço vs Vento (lag 2).....	62
Figura 19 - Resíduos da Regressão Linear.....	64

LISTA DE QUADROS

Quadro 1 - Variáveis utilizadas na análise.	31
--	----

LISTA DE TABELAS

Tabela 1 - Testes ADF e KPSS para a série do Preço do Café sem e com diferenciações.	36
Tabela 2 - Testes ADF e KPSS para a série da Precipitação.	37
Tabela 3 - Testes AIC, HQ, SC e FPE para a Precipitação.....	38
Tabela 4 - Equação do VAR de Preço vs Precipitação (lag 1)	39
Tabela 5 - Equação do VAR de Preço vs Precipitação (lag 5).	39
Tabela 6 - Decomposição da Variância – Precipitação (lag 1).....	40
Tabela 7 - Testes ADF e KPSS para Pressão.....	40
Tabela 8 - Testes AIC, HQ, SC e FPE para a Pressão.	42
Tabela 9 - Decomposição da Variância – Pressão (lag 1).....	42
Tabela 10 - Testes ADF e KPSS para a Radiação.....	43
Tabela 11 – Testes e Equação do VAR: Preço vs Radiação (lag 1).	44
Tabela 12 - Decomposição da Variância – Radiação (lag 1).....	45
Tabela 13 - Testes ADF e KPSS para Temp. de Bulbo.....	45
Tabela 14 - Testes AIC, HQ, SC e FPE para a Temp. de Bulbo.	46
Tabela 15 - Equação do VAR: Preço vs Temp. de Bulbo (lag 2).....	47
Tabela 16 - Equação do VAR: Preço vs Temp. de Bulbo (lag 3).....	47
Tabela 17 - Equação do VAR: Preço vs Temp. de Bulbo (lag 4).....	48
Tabela 18 - Equação do VAR: Preço vs Temp. de Bulbo (lag 5).....	48
Tabela 19 - Equação do VAR: Preço vs Temp. de Bulbo (lag 6).....	49
Tabela 20 - Comparativo dos resultados da Decomposição da Variância: Preço vs Temp. de Bulbo.	50
Tabela 21 - Testes ADF e KPSS para Temp. de Orvalho.	52
Tabela 22 - Testes AIC, HQ, SC e FPE para a Temp. de Orvalho.....	53
Tabela 23 - Equação do VAR: Preço vs Temp. de Orvalho (lag 1).	53
Tabela 24 - Equação do VAR: Preço vs Temp. de Orvalho (lag 2).	54
Tabela 25 - Equação do VAR: Preço vs Temp. de Orvalho (lag 3).	54

Tabela 26 - Comparativo dos resultados da Decomposição da Variância: Preço vs Temp. de Orvalho.....	55
Tabela 27 - Testes ADF e KPSS para Umidade.	56
Tabela 28 - Testes e Equação do VAR: Preço vs Umidade (lag 1).....	57
Tabela 29 - Decomposição da Variância – Radiação (lag 1).....	58
Tabela 30 - Testes ADF e KPSS para o Vento.	59
Tabela 31 - Testes AIC, HQ, SC e FPE para o Vento.....	60
Tabela 32 - Equação do VAR:Preço vs Vento (lag 1).	60
Tabela 33 - Equação do VAR de Preço vs Vento (lag 2).....	60
Tabela 34 - Equação do VAR de Preço vs Vento (lag 3).....	61
Tabela 35 - Decomposição da Variância: Preço vs Vento (lags 1,2 e 3).....	61
Tabela 36 - Regressão Linear Múltipla.....	63
Tabela 37 - Seleção Stepwise.....	63
Tabela 38 - Teste de Normalidade – Shapiro-Wilk.....	64
Tabela 39 - Regressão Linear Simples: Precipitação.....	65
Tabela 40 - Regressão Linear Simples: Pressão.	65
Tabela 41 - Regressão Linear Simples: Radiação.	66
Tabela 42 - Regressão Linear Simples: Temp. de Bulbo.	66
Tabela 43 - Regressão Linear Simples: Temp.de Orvalho.....	66
Tabela 44 - Regressão Linear Simples: Umidade.....	67
Tabela 45 - Regressão Linear Simples: Precipitação.....	67
Tabela 46 – Resumo dos resultados obtidos.	68

LISTA DE ABREVIATURAS E SIGLAS

ABIC	Associação Brasileira da Indústria do Café
ADF	<i>Augmented Dickey-Fuller</i>
AIC	<i>Aikaike Information Criterion</i>
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CNA	Confederação da Agricultura e Pecuária do Brasil
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FIR	Função Impulso-Resposta
FPE	<i>Final Prediction Error</i>
HQ	<i>Hannan-Quinn Criterion</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IEC	Instituto de Estudos Climáticos
INMET	Instituto Nacional de Meteorologia
IPCC	Intergovernmental Panel on Climate Change
IPEA	Instituto de Pesquisas Econômicas Aplicadas
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
MQO	Mínimos Quadrados Ordinários
OIC	Organização Internacional do Café
SC	<i>Schwarz Criterion</i>
VAR	Vetor Autorregressivo

SUMÁRIO

1	INTRODUÇÃO	15
1.1	CONTEXTUALIZAÇÃO	15
1.2	OBJETIVOS	16
1.2.1	Objetivo Geral	16
1.2.2	Objetivos Específicos	16
1.3	JUSTIFICATIVA	16
1.4	DELIMITAÇÕES	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	O AGRONEGÓCIO NO BRASIL	18
2.2	O MERCADO DO CAFÉ	19
2.2.1	O preço do café no Brasil	20
2.3	VARIAÇÕES CLIMÁTICAS	20
2.3.1	Variações do Clima no estado do Espírito Santo	22
2.4	SÉRIES TEMPORAIS	22
2.4.1	Estacionariedade de Séries Temporais	23
2.4.2	Teste ADF (<i>Augmented Dickey-Fuller</i>)	24
2.5	VETORES AUTORREGRESSIVOS	25
2.5.1	Causalidade de Granger	27
2.5.2	Função Impulso-Resposta (FIR)	27
2.6	REGRESSÃO LINEAR	27
2.6.1	Regressão Linear Simples	28
2.6.2	Regressão Linear Múltipla	28
3	PROCEDIMENTOS METODOLÓGICOS	29
3.1	CARACTERIZAÇÃO DA PESQUISA	29
3.2	METODOLOGIA PROPOSTA	29

3.3	FERRAMENTAS UTILIZADAS	30
3.4	ETAPAS DA PESQUISA	30
3.4.1	Definição das variáveis	31
3.4.2	Coleta e tratamento dos dados	31
3.4.3	Análise de causalidade nas séries temporais.....	32
4	APRESENTAÇÃO DOS RESULTADOS	34
4.1	CAUSALIDADE DAS SÉRIES TEMPORAIS.....	34
4.1.1	Resultados da análise defasada das séries temporais	34
4.1.2	Resultados da análise contemporânea das variáveis	62
4.1.3	Considerações Finais sobre os Resultados	67
5	CONCLUSÃO	69
	REFERÊNCIAS.....	71

1 INTRODUÇÃO

Neste capítulo será contextualizado o ambiente no qual se insere o presente trabalho. Serão apresentadas as justificativas para a escolha e a importância do mesmo, além da definição do objetivo geral, de seus objetivos específicos e apresentação de suas delimitações.

1.1 CONTEXTUALIZAÇÃO

No Brasil, o agronegócio é fundamental para a economia com grande importância para o equilíbrio da balança comercial brasileira. O PIB do agronegócio, calculado pelo Centro de Estudos Avançados em Economia Aplicada (Cepea) em parceria com a Confederação da Agricultura e Pecuária do Brasil (CNA), avançou importantes 24,3% no ano de 2020, alcançando participação considerável de 26,1% do PIB brasileiro. O país é referência na exportação e na produção de insumos de grande importância nacional e internacional.

De acordo com o Incaper (Instituto Capixaba de Pesquisa, Assistência Técnica e Extensão Rural) (2021), o Espírito Santo é o 2º maior produtor brasileiro de café e responsável por mais de 30% da produção brasileira. Atualmente, existem 402 mil hectares em produção no Estado e a atividade cafeeira é responsável por 37% do Produto Interno Bruto (PIB) Agrícola capixaba.

Dentre os tipos mais produzidos de café na região, destacam-se o conilon e o arábica. Este último, é uma espécie originária da Etiópia e uma das primeiras a serem consumidas no mundo. Dados da EMBRAPA (2022) mostram que o café arábica corresponde a 67% da produção dos Cafés do Brasil no mesmo ano.

No entanto, esse tipo de negócio vem sendo altamente afetado por variações climáticas nos últimos anos. De acordo com os dados e boletins do INMET (Instituto Nacional de Meteorologia) (2021), o ano de 2021 teve o inverno mais seco dos últimos 4 anos na região sudeste do Brasil, e conseqüentemente, o país recebeu notícias diárias de "queimas" de lavouras em nessa e em diversas regiões do país também por conta de fortes ondas de geadas não vistas por longos tempos.

1.2 OBJETIVOS

Nas seções abaixo estão descritos o objetivo geral e os objetivos específicos do presente trabalho.

1.2.1 Objetivo Geral

Analisar como as variáveis climáticas impactam o preço do café arábica no estado do Espírito Santo.

1.2.2 Objetivos Específicos

- Identificar as variáveis climáticas mais influentes na flutuação dos preços do café;
- Avaliar os atrasos temporais mais significativos que impactam as variações nos preços do café;
- Examinar como variações climáticas contemporâneas se relacionam com os preços do café;
- Explorar as interações entre as diferentes variáveis climáticas que têm impacto nos preços do café;

1.3 JUSTIFICATIVA

O preço do café tem variado muito nos últimos anos, chegando a ter sua marca mais alta na série histórica em novembro de 2022 (CEPEA, 2024). A redução da oferta no Brasil, maior produtor mundial, em função de geadas e seca, somada ao salto nos custos de fertilizantes e falta de contêineres fez o preço do café bater recorde dos últimos 7 anos (EXAME, 2022).

No Brasil, a região sudeste se destaca por ser a maior produtora do insumo, tendo Minas Gerais, Espírito Santo e o norte do estado de São Paulo como principais centros produtores do país (EMBRAPA, 2022).

As mudanças climáticas tornarão muito mais difícil o cultivo do café arábica nos próximos anos (PLOS ONE, 2022). Os estudos realizados pela revista científica Plos One, ainda indicam que as plantas de café serão “drasticamente” menos

adequadas para o cultivo nas atuais regiões produtoras de café até 2050, devido aos impactos das mudanças climáticas.

Além disso, a vulnerabilidade da agricultura frente às mudanças climáticas é uma preocupação central também para a economia global, dado que o café é uma *commodity* de alto valor e possui uma cadeia produtiva extensa e diversificada (IPCC, 2022).

Diante desses desafios, entender como as variáveis climáticas impactam o preço do café é essencial para a sustentabilidade da cafeicultura e o planejamento econômico da região. Este trabalho busca contribuir com essa análise, oferecendo uma visão prática sobre a influência do clima no mercado do café, especialmente no Espírito Santo, uma área de produção importante.

1.4 DELIMITAÇÕES

A área de estudo será limitada ao estado do Espírito Santo, uma das principais regiões produtoras de café do Brasil, com foco nas regiões produtoras de café arábica mais relevantes. Este estudo abordará o período de 2018 a 2022, utilizando dados mensais das variáveis climáticas e do preço da saca do café arábica. Este período escolhido reflete um cenário recente, onde é possível capturar as variações de preço e eventos climáticos significativos. Os resultados serão limitados à interpretação estatística, com foco nas correlações observadas e na avaliação de possíveis causalidades entre as variáveis climáticas e o preço do café. Esta análise tem como objetivo fornecer uma base para estudos futuros mais aprofundados, sem abordar aspectos socioeconômicos mais amplos relacionados ao mercado do café na região. Vale ressaltar que, durante o período analisado, o mundo enfrentou uma pandemia e cenários de guerra, eventos que, embora não sejam o foco deste estudo, podem ter tido um impacto significativo na variação dos preços deste insumo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 O AGRONEGÓCIO NO BRASIL

Segundo estudos realizados pelo Centro de Estudos Avançados em Economia Aplicada (CEPEA) (2022), da Esalq/USP, em parceria com a CNA (Confederação da Agricultura e Pecuária do Brasil), o PIB do agronegócio do Brasil, alcançou recordes sucessivos em 2020 e em 2021, com esses dois anos se caracterizando como um dos melhores da história do agronegócio brasileiro. No entanto, o cenário começou diferente em 2022, o PIB do setor iniciou o ano com decréscimo de 0,8% no primeiro trimestre. A pesquisa ainda aponta, que o setor agrícola, especificamente, começou com uma queda de 0,75%.

O comportamento de queda nesse período pode ser explicado pelo resultado negativo de culturas agrícolas relevantes para o período, de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE). Dentre os principais insumos da agricultura do país, pode-se citar, a soja, o café, o açúcar e o suco de laranja. Nesses quatro, o Brasil é o maior produtor e exportador do mundo (IBGE, 2020).

Figura 1 – Produção e Exportações Brasileiras no Ranking Mundial em 2020.



Fonte: IBGE / Elaboração CNA (2020).

A produção do café, no Brasil, ocupa uma área de 2 milhões de hectares com cerca de 300 mil produtores, em aproximadamente 1.900 municípios, distribuídos nos

Estados de Minas Gerais, São Paulo, Espírito Santo, Bahia, Rondônia, Paraná, Rio de Janeiro, Goiás, Mato Grosso, Amazonas e Pará, segundo dados do do Ministério da Agricultura, Pecuária e Abastecimento (2018).

Para o ano de 2022, a Conab (Companhia Nacional de Abastecimento) prevê a colheita de 26,9 milhões de sacas. Atualmente a produção da espécie arábica concentra-se nos Estados de Minas Gerais, São Paulo, Espírito Santo e Bahia. Esses quatro estados concentram 85% da produção nacional dessa espécie (CONAB, 2022).

2.2 O MERCADO DO CAFÉ

O café está presente na rotina de grande parte da população brasileira, sendo a segunda bebida mais ingerida no país, atrás apenas da água. Segundo dados divulgados pelo IBGE (2020), 79% dos brasileiros consomem café diariamente, e ele está presente em 98% dos lares. O consumo médio diário de café por pessoa é de três a quatro xícaras de 50ml, totalizando 78,5 litros por ano. Apesar de alguns itens básicos demonstrarem forte redução de consumo no Brasil após o início da pandemia, com o café foi o contrário. A Associação Brasileira da Indústria de Café, mostra que a bebida foi 35% mais consumida desde março de 2020 (ABIC, 2021).

Existem mais de 60 tipos de café e, no Brasil, as mais conhecidas são a Arábica e a Robusta. Essas duas variedades são as que os consumidores compram com mais frequência nas lojas, consomem em cafeterias e preparam em casa. A principal diferença quando pensamos no cultivo desses dois tipos de grãos é que as plantas de café robusta são mais resistentes, podem crescer em altitudes menores e levam menos tempo para serem produzidas. O café arábica, por outro lado, precisa ser cultivado em altitudes mais elevadas, clima mais ameno e até com certos cuidados especiais.

O Brasil é o maior produtor de café do mundo e sua produção pode ser observada em quase todos os estados do país, mas algumas áreas concentram a maior parte da produção. Dentre elas, destacam-se a região do sul de Minas Gerais, do norte de São Paulo e algumas regiões do estado do Espírito Santo (EMBRAPA, 2022).

No estado capixaba, atualmente, existem 160 mil hectares de café arábica em produção, em 48 municípios, com 53 mil famílias na atividade. A cafeicultura de

arábica gera em torno de 150 mil empregos diretos e indiretos, sendo a principal fonte de renda em 80% das propriedades rurais capixabas localizadas em terras frias e montanhosas (INCAPER, 2022).

2.2.1 O preço do café no Brasil

Nos últimos anos, o mercado cafeeiro brasileiro tem enfrentado uma série de desafios que refletem diretamente nos preços do produto. Segundo a Embrapa (2017), a volatilidade dos preços é uma constante, com o menor valor registrado em julho de 2002, quando a saca foi comercializada por R\$287,00, e o maior em abril de 1977, atingindo R\$4.706,00. Esses extremos de preço ilustram a sensibilidade do mercado às variáveis econômicas e climáticas.


Em um relatório mais recente da Associação Brasileira da Indústria de Café (Abic), observa-se que, no triênio passado, houve um aumento de 107% no preço do café pago pela indústria e de 73% no varejo (Abic, 2020). Esse incremento é atribuído ao crescimento dos custos de produção, exacerbados por condições climáticas desfavoráveis, como secas e chuvas irregulares.

Além disso, a Organização Internacional do Café e o Departamento Intersindical de Estatística e Estudos Socioeconômicos destacaram um aumento de 56,87% no preço do café nos últimos 12 meses, marcando o maior valor em 25 anos (OIC & DIEESE, 2021). Em dezembro de 2021, a saca de 60 kg, que custava aproximadamente R\$660 em janeiro, foi valorizada para R\$1.480, segundo dados do Cepea da USP (2021). Tais estudos ressaltam a importância de fatores externos na determinação dos preços do café e a necessidade de estratégias adaptativas por parte dos produtores.

2.3 VARIAÇÕES CLIMÁTICAS

Em virtude de sua grande extensão territorial e também de sua localização, o Brasil apresenta diferentes tipos de clima. Dentre os principais, podemos citar: tropical, subtropical, tropical semiárido, tropical de altitude, tropical atlântico e equatorial úmido. Além desses fatores, cada região ainda apresenta variações climáticas ao longo do ano, o que exige um maior estudo sobre a localização por parte dos agricultores brasileiros.

Figura 2 – Climas do Brasil.



Fonte: Suporte Geográfico 77.

No início dos anos 90, o Ministério da Agricultura solicitou ao Instituto de Pesquisas Econômicas Aplicadas (IPEA) do Ministério do Desenvolvimento, um estudo que pudesse identificar as principais causas das perdas na agricultura brasileira e os números indicaram que 95% das perdas foram por seca ou excesso de chuva (GUEDES, 2009).

Analisando o cenário do sudeste brasileiro no inverno de 2021, as temperaturas ficaram abaixo do normal em mais de 2°C em seus estados, com exceção do Rio de Janeiro. No Espírito Santo, além da variação da temperatura, também constatou-se uma redução nas chuvas, com 10 milímetros a menos para setembro, quando comparado com o mesmo mês do ano anterior, e em outubro secou ainda mais (INMET, 2022).

2.3.1 Variações do Clima no estado do Espírito Santo

Nos últimos anos, o Espírito Santo tem sido palco de notáveis variações climáticas, que têm afetado tanto o meio ambiente quanto a população. Um estudo do Instituto de Estudos Climáticos (IEC) utilizou modelagem regional de alta resolução para projetar mudanças climáticas no estado, indicando que o Espírito Santo pode sofrer alterações significativas em temperatura e precipitação, dependendo dos cenários de emissão de gases de efeito estufa e desenvolvimento socioeconômico (IEC, 2020).

O Instituto Nacional de Meteorologia (INMET) fornece dados que revelam as características médias do clima no Espírito Santo, baseadas em observações históricas de períodos de 30 anos. Esses dados são fundamentais para compreender as normais climatológicas e suas mudanças ao longo do tempo, refletindo as tendências de variação climática no estado (INMET, 2020).

Adicionalmente, pesquisas indicam que o Espírito Santo é o estado brasileiro mais afetado por temperaturas extremas. Nos últimos 40 anos, a frequência de eventos extremos de temperatura quase triplicou no estado, um fenômeno intensificado por condições específicas como os fenômenos El Niño e La Niña (G1, 2023). Essas variações têm implicações diretas em todos os setores da economia e da sociedade, ressaltando a necessidade de políticas de adaptação às novas condições climáticas.

2.4 SÉRIES TEMPORAIS

As séries temporais são conjuntos de observações coletadas em determinados intervalos de tempo, em sua maioria, são apresentados em sequência cronológica. Pode-se observar o uso dessas séries em diversas áreas, como economia, finanças, meteorologia e engenharia, para modelar e prever padrões de comportamento ao longo do tempo (MAKRIDAKIS ET AL., 1998).

Para analisar séries temporais, busca-se a identificação de tendências, sazonalidades e padrões cíclicos nos dados, bem como a aplicação de métodos estatísticos e modelos matemáticos para extrair informações úteis e fazer projeções futuras (CHATFIELD, 2004).

Uma das características das séries temporais é sua natureza dinâmica, onde as observações estão inter-relacionadas no tempo, o que implica que o valor de uma observação em um momento específico pode depender dos valores anteriores e, às vezes, das condições presentes (BOX ET AL., 2015).

Na literatura, encontram-se várias técnicas e modelos para analisar e prever séries temporais, cada um com suas características próprias, vantagens e limitações. Alguns dos métodos comuns incluem modelos auto-regressivos, modelos de médias móveis, e modelos de médias móveis auto-regressivos (HAMILTON, 1994). Além disso, métodos mais avançados, como modelos autoregressivos integrados de médias móveis (ARIMA) e redes neurais artificiais (RNA), têm sido amplamente explorados para lidar com séries temporais complexas e não lineares (HYNDMAN & ATHANASOPOULOS, 2018).

2.4.1 Estacionariedade de Séries Temporais

É comum observar em técnicas de séries temporais, que supõe-se que os dados sejam estacionários. Um vetor autorregressivo precisa ser composto, necessariamente, de séries temporais estacionárias, de modo que as variáveis sejam afetadas somente pelos valores passados e atuais da própria variável (ENDERS, 2004).

Um processo estacionário tem a propriedade de que a média, variância e estrutura de autocorrelação não mudam no decorrer do tempo (BERTOLO, 2012). Para Bertolo (2012), se a série temporal não for estacionária, pode-se frequentemente transformá-la em estacionária utilizando diferentes técnicas:

- a) Diferenciando os dados, ou seja, dada uma série Z_t , cria-se uma nova série:

$$Y(i) = Z(i) - Z(i-1)$$

Desta forma, os novos dados encontrados a partir da diferenciação, contém um ponto a menos que os dados originais. O processo pode ser realizado mais de uma vez, no entanto uma diferenciação geralmente é suficiente;

- b) Ajustar algum tipo de curva aos dados e depois então modelar os resíduos daquele ajuste, em casos de dados que apresentam uma tendência. Um ajuste simples, como uma linha reta, pode ser utilizado, desde que o propósito do ajuste é simplesmente remover tendências de longo prazo;
- c) Em casos de variância não constante, pode-se estabilizar a variância tomando o logaritmo ou a raiz quadrada da série. Na existência de dados negativos, pode-se adicionar uma constante adequada para tornar todos os dados positivos antes de aplicar a transformação.

2.4.2 Teste ADF (*Augmented Dickey-Fuller*)

O teste de Dickey-Fuller é amplamente utilizado para identificar a presença de raiz unitária em séries temporais, sendo aplicado em três modelos distintos (GUJARATI; PORTER, 2011):

- a) Passeio aleatório:

$$\Delta Y_t = \delta Y_{t-1} + \mu_t \quad (1)$$

- b) Passeio aleatório com termo constante:

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + \mu_t \quad (2)$$

- c) Passeio aleatório com termo constante e tendência determinística:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \mu_t \quad (3)$$

Para cada modelo, são consideradas a hipótese nula (H_0), onde $\delta = 0$, indicando que a série temporal é não estacionária e tem raiz unitária, ou a hipótese alternativa (H_1), onde $\delta < 0$, indicando que a série é estacionária, possivelmente em torno de uma tendência determinística (Enders, 2014):

Nos casos em que o termo de erro (μ_t) apresenta correlação serial, utiliza-se o teste de Dickey-Fuller Aumentado (ADF). Nesse teste, são incluídas diferenças

defasadas da série original para eliminar a correlação dos resíduos, como na equação abaixo (HAMILTON, 1994):

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + \epsilon_t \quad (4)$$

Onde:

$\Delta Y_t = Y_t - Y_{t-1}$, representa a diferença da série;

δ testa a raiz unitária (se a série é estacionária);

β_1 indicam o termo constante;

β_2 indica a tendência;

m é o número de defasagens, selecionado por critérios como AIC;

ϵ_t é o termo de erro, que deve ser não correlacionado.

A principal finalidade do teste ADF é garantir que o resíduo seja livre de correlação serial, permitindo uma avaliação mais robusta da estacionariedade da série temporal (LÜTKEPOHL, 2005).

2.5 VETORES AUTORREGRESSIVOS

Os Vetores Autorregressivos (VAR) são modelos estatísticos amplamente utilizados na análise de séries temporais multivariadas, em que duas ou mais variáveis estão inter-relacionadas ao longo do tempo (LÜTKEPOHL, 2005). Ao contrário dos modelos univariados, como os modelos ARIMA, os Vetores Autorregressivos permitem a modelagem das relações dinâmicas entre múltiplas variáveis, capturando tanto as interações de curto prazo quanto de longo prazo entre elas (ENDERS, 2014).

Para esse tipo de modelo, uma característica fundamental é a sua estrutura auto regressiva, onde cada variável é expressa como uma função linear de seus próprios valores passados, bem como dos valores passados de todas as outras variáveis no sistema (HAMILTON, 1994). Desta forma, é possível capturar como são realizadas as interações entre as variáveis ao longo do tempo, tornando os modelos

VAR uma ferramenta poderosa para a análise de sistemas dinâmicos complexos (LÜTKEPOHL, 2005).

Em geral, utiliza-se a minimização da soma dos quadrados dos resíduos para a estimação dos modelos VAR, utilizando técnicas como o método de mínimos quadrados ordinários (MQO) ou o método de máxima verossimilhança (ENDERS, 2014). Além disso, a determinação do número adequado de defasagens nos modelos VAR, influencia na captura adequada da dinâmica temporal das variáveis e evita problemas de super ajuste ou subajuste (LÜTKEPOHL, 2005).

Mesmo oferecendo uma estrutura flexível para analisar séries temporais multivariadas, é importante entender que esse tipo de modelo tem suas limitações, como a sensibilidade a choques de grande magnitude e a dificuldade de interpretar as relações causais entre as variáveis (ENDERS, 2014).

De acordo com Enders (2014), o modelo VAR é particularmente útil para analisar o inter-relacionamento entre variáveis em séries temporais multivariadas. Em um sistema de duas variáveis, por exemplo, os valores de y_t ao longo do tempo são influenciados tanto pelos valores contemporâneos quanto pelos valores defasados de z_t . Da mesma forma, os valores de z_t são afetados pelos valores contemporâneos e defasados de y_t . Essa abordagem permite capturar interações dinâmicas entre as variáveis, indo além da análise unidirecional tradicional.

O modelo estrutural VAR para duas variáveis pode ser representado pelas Equações 1 e 2:

$$y_t = b_{10} - b_{12}z_t + \gamma_{11}y_{t-1} + \gamma_{12}z_{t-1} + \varepsilon_{yt} \quad (5)$$

$$z_t = b_{20} - b_{21}y_t + \gamma_{21}y_{t-1} + \gamma_{22}z_{t-1} + \varepsilon_{zt} \quad (6)$$

Tanto a variável y_t quanto a variável z_t devem ser estacionárias, ou seja, apresentar propriedades estatísticas constantes ao longo do tempo. Os termos de erro ε_{yt} e ε_{zt} representam ruídos brancos, não correlacionados entre si e com desvio padrão constante σ (ENDERS, 2014).

2.5.1 Causalidade de Granger

Mesmo que a análise de regressão trabalhe com a dependência de uma variável em relação a outras, isso não implica necessariamente causalidade (GUJARATI, 2006).

Para sistemas temporais, Granger define causalidade em termos de previsibilidade: a variável X causa a variável Y, com respeito a um dado universo de informação (que inclui X e Y), se o presente de Y pode ser previsto mais eficientemente usando esse passado de X, do que não usando esse passado, toda e qualquer outra informação disponível (incluindo valores passados de Y) sendo usada em ambos os casos (MORETTIN, 2008).

2.5.2 Função Impulso-Resposta (FIR)

A Função Impulso-Resposta (FIR) é uma técnica usada na análise de séries temporais para avaliar o efeito dinâmico de choques em variáveis inter-relacionadas dentro de um sistema econométrico, como os modelos de Vetores Autorregressivos (VAR). Essencial para analisar como um impulso ou "choque" em uma variável afeta outras variáveis ao longo do tempo, a FIR permite visualizar a reação de cada variável a uma mudança exógena e temporária em outra, mensurando a propagação desses efeitos em intervalos específicos (LÜTKEPOHL, 2005; ENDERS, 2014).

2.6 REGRESSÃO LINEAR

A Regressão Linear é uma técnica estatística fundamental que busca modelar a relação entre uma variável dependente e uma ou mais variáveis independentes por meio de uma equação linear. Essa técnica é bastante utilizada para realizar análises exploratórias de dados, previsão e inferência causal em diversas áreas do conhecimento, como economia, ciências sociais, biologia e engenharia (MONTGOMERY ET AL., 2012).

O processo de ajuste da Regressão Linear envolve estimar os coeficientes da equação linear através de métodos como os mínimos quadrados ordinários. É essencial verificar os pressupostos da regressão linear, como a linearidade da relação

entre as variáveis, para garantir a validade dos resultados obtidos (GUJARATI & PORTER, 2009).

Dentro deste contexto, abordaremos dois importantes subtópicos: Regressão Linear Simples e Regressão Linear Múltipla.

2.6.1 Regressão Linear Simples

A Regressão Linear Simples é uma técnica utilizada quando há uma única variável independente para prever a variável dependente. Nesse caso, a relação entre as variáveis é modelada por uma linha reta. O objetivo é encontrar a melhor linha que se ajuste aos dados observados, minimizando a soma dos quadrados dos resíduos (MONTGOMERY et al., 2012).

2.6.2 Regressão Linear Múltipla

Já a Regressão Linear Múltipla é aplicada quando há mais de uma variável independente influenciando a variável dependente. Este método permite capturar a influência conjunta das variáveis independentes na variável dependente, oferecendo maior flexibilidade na modelagem de fenômenos complexos (GUJARATI & PORTER, 2009).

Esse método considera o efeito que múltiplas variáveis têm na previsão de demanda. Montgomery & Runger (2009), definem o modelo com a seguinte equação:

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon \quad (7)$$

Onde:

Y = Variável dependente;

X = Variável independente;

β = Parâmetros desconhecidos do modelo;

ε = Erro aleatório.

3 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo, são apresentados os procedimentos metodológicos adotados para a realização da pesquisa proposta neste trabalho. Será descrito o tipo de pesquisa realizada, justificando a escolha do método e apresentando como o estudo foi planejado. Em seguida, serão apresentados os dados selecionados e as ferramentas que foram utilizadas para sua coleta, seleção e validação.

3.1 CARACTERIZAÇÃO DA PESQUISA

A pesquisa realizada neste trabalho é classificada como pesquisa aplicada, onde o conhecimento gerado visa solucionar problemas específicos e tem aplicabilidade direta na prática, contribuindo para a tomada de decisões e a resolução de questões reais (GIL, 2010).

No estudo, são utilizados métodos estatísticos para analisar os valores numéricos da variação do preço do café com base nas variações climáticas, caracterizando a abordagem da pesquisa como quantitativa. Segundo Gil (2010), a pesquisa quantitativa busca quantificar e medir fenômenos por meio de dados numéricos, permitindo uma análise objetiva e rigorosa dos dados coletados.

Pode-se também caracterizar a pesquisa quanto a sua respectiva área de estudo conforme a divisão das áreas definidas pela ABEPRO (2024). Sob esse aspecto, a pesquisa se enquadra na área de Pesquisa Operacional da Engenharia de Produção.

3.2 METODOLOGIA PROPOSTA

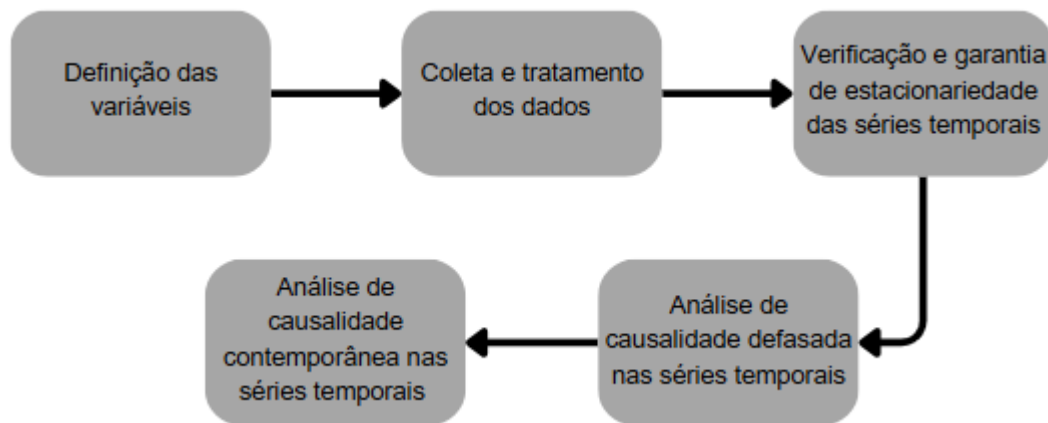
Buscando atingir o objetivo proposto, o trabalho foi dividido em etapas distintas. A primeira delas, focada em entender a relação entre as variáveis climáticas coletadas e o preço do café arábica no estado do Espírito Santo com defasagens, analisando qual delas tem maior impacto. No presente estudo, definiu-se como a variável dependente o preço do café e, portanto, as variáveis independentes como os diversos dados climáticos que podem ser obtidos naquela região. Desta forma, foi necessário nessa etapa, entender quais destas variáveis dependentes tinham relação

de causalidade. Para analisar as causalidades, foram utilizados Vetores Autorregressivos e uma análise sobre a Decomposição da Variância, a Causalidade de Granger e a Função Impulso-Resposta.

Para um segundo momento, buscou-se também analisar o impacto contemporâneo dessas variáveis e, para isso, foram aplicadas as séries a Regressão Linear Múltipla e a Regressão Linear Simples.

As etapas presentes no desenvolvimento do presente trabalho estão apresentadas na Figura 3:

Figura 3 - Etapas realizadas do trabalho.



Fonte: Elaborado pelo autor (2024)

3.3 FERRAMENTAS UTILIZADAS

As análises foram conduzidas no *software* R Studio, reconhecido por sua capacidade de realizar modelagens avançadas e análises estatísticas robustas. Gráficos e tabelas foram gerados utilizando o *software* Microsoft Excel, para facilitar a interpretação dos resultados.

3.4 ETAPAS DA PESQUISA

Sabendo-se a metodologia a ser seguida e as delimitações do trabalho, foi possível então seguir para cada uma das etapas do mesmo.

3.4.1 Definição das variáveis

A primeira necessidade foi definir quais seriam as variáveis a serem estudadas. Uma vez que estamos estudando a variação do preço do café, certamente essa é nossa primeira variável, e também a variável dependente do nosso trabalho.

Por outro lado, foi necessário buscar quais dados climáticos estavam disponíveis para entender o comportamento das variações climáticas na região do Espírito Santo. Nesse primeiro momento, foram utilizadas todas as variáveis que já são fornecidas pelo INMET para o clima. Todas as variáveis definidas estão apresentadas no Quadro 1.

Quadro 1 - Variáveis utilizadas na análise.

Tipo	Descrição da variável	Unidade (coletada a cada hora)
Dependente	Preço do Café Arábica	R\$/Saca60kg
Independente	Precipitação Total, Horário	mm
Independente	Pressão Atmosferica Ao Nivel Da Estação	mB
Independente	Radiação Global	kJ/m ²
Independente	Temperatura Do Ar - Bulbo Seco	°C
Independente	Temperatura Do Ponto De Orvalho	°C
Independente	Umidade Relativa Do Ar	%
Independente	Velocidade do Vento	m/s

Fonte: Elaborado pelo autor (2024)

3.4.2 Coleta e tratamento dos dados

Os dados das variáveis referentes às mudanças climáticas foram coletados a partir do INMET, para os anos de 2018 a 2022, nas 3 cidades do Espírito Santo: Alfredo Chaves, Venda Nova do Imigrante e Afonso Cláudio. Em um segundo momento, os dados passaram por processos de limpeza e organização, utilizando o

software Microsoft Excel, que os deixassem ajustados para aplicar os Vetores Autorregressivos e Regressão Linear. Os dados coletados estavam apresentados a cada hora do dia, no entanto, para que fosse possível analisar os dados em intervalos mensais, foi tirada uma média simples para todas as variáveis, com exceção da precipitação, onde optou-se por realizar a soma de toda a quantidade de chuva precipitada no mês.

Já os dados relacionados a variação dos preços do insumo foram coletados no portal Agrolink. Foram também analisadas outras fontes para a coleta desses dados, no entanto o portal foi o que apresentou maior uniformidade nas informações apresentadas, quando analisado o estado do Espírito Santo. Fontes como CEPEA/ESALQ/USP, apresentaram apenas dados referentes ao estado de São Paulo, e foi possível observar que os valores estavam acima do preço capixaba e abaixo da média nacional. O insumo selecionado foi a saca de 60kg do Café Arábica Tipo 6 Duro, e sua variação de preço foi observada também no intervalo de 2018 a 2022. O portal disponibiliza os preços a cada dia, semana, mês ou ano, também utilizando média simples para os resultados agregados, sendo possível escolher a preferência do modo de coleta, e desta forma, os valores foram obtidos mês a mês. Os dados passaram por processos de limpeza e organização que os deixassem ajustados para as aplicações do VAR e da Regressão Linear.

3.4.3 Análise de causalidade nas séries temporais

Na análise de causalidade defasada realizada, foram conduzidos seis ensaios, cada um envolvendo um par de variáveis, sendo uma variável dependente e uma independente. O procedimento seguido em cada ensaio incluiu as seguintes etapas:

- a) Verificação da Estacionariedade: Inicialmente, foi realizada uma avaliação da estacionariedade das séries temporais utilizando os testes ADF (*Augmented Dickey-Fuller*) e KPSS (Kwiatkowski-Phillips-Schmidt-Shin). A condição de estacionariedade foi verificada com base no valor de p , estabelecendo-se um limite máximo de 10%. Caso os testes indicassem um valor de p superior a esse limite, procedeu-se com a aplicação de diferenças nas séries para torná-las estacionárias.

- b) Aplicação de Diferenças nas Séries Não-Estacionárias: As séries que não atenderam à condição de estacionariedade, conforme os testes ADF e KPSS, passaram por um processo de diferenciação. Esse procedimento garantiu que as séries temporais se tornassem adequadas para a análise subsequente, atendendo às exigências de estacionariedade dos modelos VAR.
- c) Seleção das Defasagens: Uma vez assegurada a estacionariedade das séries, o próximo passo foi a implementação do modelo VAR (Vetores Autoregressivos). Para determinar as defasagens de maior impacto, foram estimadas equações VAR com diferentes números de defasagens. A escolha das defasagens ótimas foi baseada na análise dos *p-values*. Defasagens que apresentaram *p-values* inferiores a 0,1 e foram consideradas as mais relevantes para a modelagem.
- d) Decomposição da Variância: Após isso, realizou-se a análise de decomposição da variância para as defasagens selecionadas. O propósito dessa análise foi mensurar o quanto a variável independente explicava a variância da variável dependente ao longo de até 10 períodos. Isso permitiu uma avaliação mais detalhada das interações dinâmicas entre as variáveis ao longo do tempo.
- e) Função Impulso Resposta (FIR): Por fim, para compreender a resposta da variável dependente a choques na variável independente ao longo do tempo, foram plotados os gráficos da Função Impulso-Resposta ao longo de 10 períodos, permitindo a análise gráfica do comportamento da série ao longo do tempo.

Para a análise da causalidade contemporânea optou-se por realizar a Regressão Linear Múltipla e a Regressão Linear Simples, utilizando as séries estacionárias já obtidas nos passos anteriores.

4 APRESENTAÇÃO DOS RESULTADOS

Nesta seção, são apresentados os resultados obtidos com base nas etapas descritas na metodologia. Utilizando o software R, foram realizadas as análises necessárias para investigar as relações de causalidade entre as variáveis e identificar o modelo mais adequado para a previsão da série temporal. A partir dos dados analisados, buscou-se determinar as melhores projeções e validar os resultados através das métricas de erro previamente estabelecidas.


4.1 CAUSALIDADE DAS SÉRIES TEMPORAIS

Aqui serão apresentadas as informações resultantes da aplicação das ferramentas utilizadas para a identificação de causalidades. As análises foram organizadas em dois tópicos principais: a aplicação dos Vetores Autoregressivos (VAR), que examinam as relações defasadas entre as variáveis, e a Regressão Linear, que se concentra nas interações contemporâneas. Cada abordagem oferece uma perspectiva distinta sobre as influências entre as variáveis ao longo do tempo, permitindo uma compreensão mais abrangente das dinâmicas envolvidas.

4.1.1 Resultados da análise defasada das séries temporais

A variável definida como dependente será dada pela série temporal com os preços mensais da saca de café. Os valores da série vão de janeiro de 2018 até dezembro de 2022. A Figura 4 mostra o gráfico da série temporal do Preço.

Figura 4 - Série Temporal de Preço da Saca de Café.



Fonte: Elaborado pelo autor (2024)

A primeira etapa do procedimento é a de verificação da estacionariedade da série temporal. Para isso, foram aplicados os testes ADF e KPSS e as Figuras 5 e 6 mostram que, originalmente, a série do preço não é estacionária, pois apresenta valores para o p-value maiores que 0,1.

Figura 5 - Teste ADF para a Série Temporal do Preço do Café.

Augmented Dickey-Fuller Test
data: preco
Dickey-Fuller = -2.2102, Lag order = 3, p-value = 0.4898
alternative hypothesis: stationary

Fonte: Elaborado pelo autor (2024)

Figura 6 - Teste KPSS para a Série Temporal do Preço do Café.

#####
KPSS Unit Root / Cointegration Test
#####
The value of the test statistic is: 1.2303

Fonte: Elaborado pelo autor (2024)

Com o resultado obtido, foi necessário aplicar diferenciações na série e refazer os testes. A Tabela 1, apresenta os resultados obtidos para a série temporal do preço com uma diferenciação e com duas diferenciações. No segundo caso, os valores obtidos para o p-value são menores que 0,1 e, desta forma, a condição de estacionariedade foi atingida.


Tabela 1 - Testes ADF e KPSS para a série do Preço do Café sem e com diferenciações.

Séries	Testes	
	ADF	KPSS
preco	0,4898	1,2303
preco_dif	0,2113	0,1336
preco_dif2	0,0100	0,0364

Fonte: Elaborado pelo autor (2024)

A Figura 7, apresenta graficamente a Série Temporal do Preço com duas diferenciações, com a condição de estacionariedade atingida.

Figura 7 - Série Temporal de Preço da Saca de Café.



Fonte: Elaborado pelo autor (2024)

Definida a Série Temporal do Preço que será trabalhada, iniciam-se as análises para cada uma das variáveis independentes, onde os resultados mais aceitáveis foram apresentados para a Temperatura de Bulbo Seco, a Temperatura do ponto de Orvalho e o Vento. Para manter a organização, os resultados são apresentados na mesma ordem em que as séries foram analisadas durante todo o trabalho.

4.1.1.1 Precipitação

A primeira variável independente analisada foi a Precipitação, com valores observados de janeiro de 2018 a dezembro de 2022. Os testes de raiz unitária ADF e KPSS foram aplicados à série original e com diferenciações, e a Tabela 2 nos mostra

que a Série Temporal da Precipitação foi aprovada originalmente, sem a necessidade de diferenciações.


Tabela 2 - Testes ADF e KPSS para a série da Precipitação.

Séries	Testes	
	ADF	KPSS
precip	0,0100	0,0830
precip_dif	0,0667	0,0670
precip_dif2	0,0100	0,0682

Fonte: Elaborado pelo autor (2024)

Com valores para o *p-value* abaixo de 0,1 em ambos os testes, a série original da precipitação sem nenhuma diferenciação, foi definida para a continuidade da análise. A Figura 8 mostra graficamente a série temporal da precipitação.


Figura 8 - Série Temporal Precipitação.



Fonte: Elaborado pelo autor (2024)

O próximo passo é a seleção da melhor defasagem e para isso será aplicado o modelo dos Vetores Autorregressivos (VAR). Para que isso seja possível, é necessário a criação de uma nova série temporal que una as duas séries a serem analisadas. A Figura 9 apresenta a nova série criada, que une o Preço e a Precipitação.

Figura 9 - Série Temporal do Preço com a Precipitação.



Fonte: Elaborado pelo autor (2024)

A partir da nova série, inicia-se o procedimento para verificar as melhores defasagens.. Em um primeiro momento, foram aplicados os testes AIC (Akaike Information Criterion), HQ (Hannan-Quinn Criterion), SC (Schwarz Criterion) e FPE (Final Prediction Error). A Tabela 3, mostra o resultado com os melhores lags indicados conforme cada um dos testes.

Tabela 3 - Testes AIC, HQ, SC e FPE para a Precipitação.

Melhor lag para Precipitação:			
AIC(n)	HQ(n)	SC(n)	FPE(n)
5	1	1	5

Fonte: Elaborado pelo autor (2024)

Em seguida, com os valores obtidos, foi rodado o modelo VAR com defasagens de 1 a 6 períodos, para poder analisar todo o intervalo com os melhores resultados sugeridos pelos testes AIC, HQ, SC e FPE. No entanto, nenhuma das equações obtidas foram aceitáveis, apresentando os *p-values*, associados ao teste de significância das variáveis do modelo, acima do valor aceitável de 0,1. A Tabela 4 e a Tabela 5, mostram os resultados obtidos para os *lags* 1 e 5, que em um primeiro momento foram sugeridas.

Tabela 4 - Equação do VAR de Preço vs Precipitação (*lag 1*)

Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + precip.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.26217	0.15857	-1.653	0.104
precip.l1	-0.02562	0.08067	-0.318	0.752
const	2.57181	10.75385	0.239	0.812

Fonte: Elaborado pelo autor (2024)

Tabela 5 - Equação do VAR de Preço vs Precipitação (*lag 5*).

Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + precip.l1 + preco_dif2.l2 + precip.l2 + preco_dif2.l3 + precip.l3 + preco_dif2.l4 + precip.l4 + preco_dif2.l5 + precip.l5 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.39356	0.15951	-2.467	0.01778 *
precip.l1	-0.02956	0.09924	-0.298	0.76727
preco_dif2.l2	-0.48788	0.17111	-2.851	0.00673 **
precip.l2	0.01574	0.10166	0.155	0.87766
preco_dif2.l3	-0.35272	0.18762	-1.88	0.06706 .
precip.l3	-0.06814	0.1049	-0.65	0.51952
preco_dif2.l4	-0.34505	0.18978	-1.818	0.07617 .
precip.l4	-0.09929	0.10193	-0.974	0.33558
preco_dif2.l5	-0.53148	0.18435	-2.883	0.00619 **
precip.l5	-0.06542	0.09689	-0.675	0.50321
const	22.05077	15.86486	1.39	0.17188

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Fonte: Elaborado pelo autor (2024)

Além dos resultados do VAR, também foi analisada a decomposição da variância para os *lags* de 1 a 6. A Tabela 6 apresenta os resultados obtidos no décimo período de cada *lag*.

Tabela 6 – Decomposição da Variância – Precipitação (*lag 1*).

	\$preco_dif2	<i>lag 1</i>
	preco_dif2	precip
[1,]	1.0000000	0.0000000
[2,]	0.9985661	0.0014339
[3,]	0.9985413	0.0014587
[4,]	0.9985137	0.0014863
[5,]	0.9985115	0.0014885
[6,]	0.9985108	0.0014892
[7,]	0.9985107	0.0014893
[8,]	0.9985107	0.0014893
[9,]	0.9985107	0.0014893
[10,]	0.9985107	0.0014893

Fonte: Elaborado pelo autor (2024)

Com isso, verificou-se que a precipitação não tem um impacto significativo na série temporal do preço. No entanto, observou-se que há um auto impacto entre todos os coeficientes do preço defasado com o contemporâneo.

4.1.1.2 Pressão

A variável seguinte a ser analisada foi a Pressão, com valores observados de janeiro de 2018 a dezembro de 2022. Os testes de raiz unitária ADF e KPSS foram aplicados à série original e com diferenciações, e a Tabela 7 nos mostra que a Série Temporal da Pressão foi aprovada originalmente, sem a necessidade de diferenciações.


Tabela 7 - Testes ADF e KPSS para Pressão.

Séries	Testes	
	ADF	KPSS
pressao	0,0100	0,0356
pressao_dif	0,0100	0,0386
pressao_dif2	0,0100	0,0330

Fonte: Elaborado pelo autor (2024)

Em ambos os testes, a série original da pressão, sem diferenciações, apresentou valores para o p -value abaixo de 0,1 e, assim, com a estacionariedade garantida, foi criada a nova série combinada com a série temporal do preço, sendo esta então a abordada para a composição deste VAR. A Figura 10 mostra graficamente a série temporal da combinada da pressão e do preço.

Figura 10 - Série Temporal do Preço com a Pressão.



Fonte: Elaborado pelo autor (2024)

A partir da nova série, inicia-se o procedimento para verificar as melhores defasagens. Aqui, também foi rodado o modelo VAR para defasagens de 1 a 6 e, assim como para a Precipitação, todas as equações no modelo para a Pressão apresentou os p -values, associados ao teste de significância das variáveis do modelo, acima do valor aceitável de 0,1. A Tabela 8, mostra que o resultado para os melhores $lags$ indicados pelos testes AIC, HQ, SC e FPE é 1 e também apresenta o resultado obtido no VAR para esse mesmo lag .

Tabela 8 - Testes AIC, HQ, SC e FPE e VAR de Preço vs Pressão (*lag 1*).

Melhor lag para Pressão:				
	AIC(n)	HQ(n)	SC(n)	FPE(n)
	1	1	1	1
Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + pressao.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2616	0.158	-1.656	0.104
pressao.l1	0.8102	1.5284	0.53	0.598
const	-784.6748	1480.4068	-0.53	0.598

Fonte: Elaborado pelo autor (2024)

A Tabela 9 apresenta os resultados para a decomposição da variância para os lags de 1 a 6 após dez passos de tempo.

Tabela 9 – Decomposição da Variância – Pressão (*lag 1*).

	\$preco_dif2	<i>lag 1</i>
	preco_dif2	pressao
[1,]	1.0000000	0.0000000
[2,]	0.9951602	0.0048398
[3,]	0.9949387	0.0050613
[4,]	0.9949238	0.0050762
[5,]	0.9949229	0.0050771
[6,]	0.9949228	0.0050772
[7,]	0.9949228	0.0050772
[8,]	0.9949228	0.0050772
[9,]	0.9949228	0.0050772
[10,]	0.9949228	0.0050772

Fonte: Elaborado pelo autor (2024)

Os resultados obtidos na decomposição da variância, reforçam um baixo impacto das variáveis na série do preço, apresentando 0,1 Com isso, verificou-se que a pressão não tem um impacto significativo na série temporal do preço.

4.1.1.3 Radiação

Para a radiação, os testes de raiz unitária ADF e KPSS foram aplicados à série original e com diferenciações, e a Tabela 10 nos mostra que a Série Temporal da Radiação foi aprovada originalmente, sem a necessidade de diferenciações.


Tabela 10 - Testes ADF e KPSS para a Radiação.

Séries	Testes	
	ADF	KPSS
radiacao	0,0264	0,0739
radiacao_dif	0,0100	0,0442
radiacao_dif2	0,0100	0,0686

Fonte: Elaborado pelo autor (2024)

Em ambos os testes, a série original da radiação, sem diferenciações, apresentou valores para o p -value abaixo de 0,1 e, assim, com a estacionariedade garantida, foi criada a nova série combinada com a série temporal do preço, sendo esta então a abordada para a composição deste VAR. A Figura 11 mostra graficamente a série temporal da combinada da radiação e do preço.

Figura 11 - Série Temporal do Preço com a Radiação.



Fonte: Elaborado pelo autor (2024)

Seguiu-se então com o procedimento, rodando os testes AIC, HQ, SC e FPE e aplicando o modelo VAR para as defasagens de 1 a 6, onde observou-se que o melhor lag para os testes é 1, mas que ao observar os resultados do modelo VAR, nenhuma das equações no modelo para a Radiação apresentou os *p-values*, associados ao teste de significância das variáveis do modelo, acima do valor aceitável de 0,1. A Tabela 11, mostra os resultados dos testes AIC, HQ, SC e FPE e também apresenta o resultado obtido no VAR para o lag 1.

Tabela 11 – Testes e Equação do VAR: Preço vs Radiação (lag 1)

Melhor lag para Radiação:				
	AIC(n)	HQ(n)	SC(n)	FPE(n)
	1	1	1	1
Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + radiacao.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2561	0.1607	-1.5930	0.1170
radiacao.l1	0.0027	0.0332	0.0800	0.9360
const	-3.5186	45.2864	-0.0780	0.9380

Fonte: Elaborado pelo autor (2024)

Além da análise do VAR, também foi realizada a decomposição da variância para o lag 1, onde foi possível observar o impacto da variável após dez passos de tempo. A Tabela 12 apresenta os resultados obtidos.

Tabela 12 – Decomposição da Variância - Radiação (lag 1)

	\$preco_dif2	lag 1
	preco_dif2	radiacao
[1,]	1.0000000	0.0000000
[2,]	0.9988036	0.0011964
[3,]	0.9888908	0.0111093
[4,]	0.9890728	0.0109272
[5,]	0.9887872	0.0112128
[6,]	0.9887055	0.0112945
[7,]	0.9887073	0.0112927
[8,]	0.9886982	0.0113018
[9,]	0.9886975	0.0113025
[10,]	0.9886974	0.0113026

Fonte: Elaborado pelo autor (2024)

Nota-se que o impacto no décimo período é de aproximadamente 1%, o que reforça junto ao VAR a afirmação de que a pressão não tem um impacto significativo na série temporal do preço.

4.1.1.4 Temperatura do Ar - Bulbo Seco

Para a Temperatura de Bulbo, com valores observados de janeiro de 2018 a dezembro de 2022, foram aplicados os testes de raiz unitária ADF e KPSS à série original e com diferenciações, e a Tabela 13 nos mostra que a Série Temporal da Temperatura de Bulbo foi aprovada originalmente, sem a necessidade de diferenciações.


Tabela 13 - Testes ADF e KPSS para Temp. de Bulbo.

Séries	Testes	
	ADF	KPSS
temp_bulbo	0,0100	0,0918
temp_bulbo_dif	0,0100	0,0440
temp_bulbo_dif2	0,0100	0,0347

Fonte: Elaborado pelo autor (2024)

Observou-se então que, para a série original da temperatura de bulbo, sem diferenciações, os *p-value* se apresentaram abaixo de 0,1 e, assim, com a estacionariedade garantida, foi criada a nova série combinada com a série temporal do preço, sendo esta então a abordada para a composição deste VAR. A Figura 12 mostra graficamente a série temporal da combinada da pressão e do preço.

Figura 12 - Série Temporal do Preço e Temp. de Bulbo.



Fonte: Elaborado pelo autor (2024)

A partir da nova série, iniciou-se o procedimento para verificar as melhores defasagens. A Tabela 14, mostra o resultado com os melhores *lags* indicados pelos testes AIC, HQ, SC e FPE.

Tabela 14 - Testes AIC, HQ, SC e FPE para a Temp. de Bulbo.

Melhor lag para Temp_Bulbo:			
AIC(n)	HQ(n)	SC(n)	FPE(n)
5	2	2	5

Fonte: Elaborado pelo autor (2024)

Os testes AIC e FPE indicam que o melhor *lag* para a série da temperatura de bulbo é 5, enquanto os testes HQ e SC indicam que o melhor *lag* é 2. Foi então rodado o modelo VAR com defasagens de 1 a 6 períodos e, para a Temperatura de Bulbo, todas as equações obtidas pelo modelo VAR, a partir de 2 defasagens, apresentaram valores aceitáveis, ou seja, apresentou os *p-values*, associados ao teste de

significância das variáveis do modelo, acima do valor aceitável de 0,1 As Tabelas 15 a 19, apresentam os resultados obtidos em para os lags 2, 3, 4, 5 e 6, respectivamente.

Tabela 15 - Equação do VAR: Preço vs Temp. de Bulbo (lag 2)

Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + temp_bulbo.l1 + preco_dif2.l2 + temp_bulbo.l2 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.4499	0.1659	-2.712	0.00908 **
temp_bulbo.l1	-13.7379	5.9359	-2.314	0.02471 *
preco_dif2.l2	-0.2334	0.1612	-1.448	0.15374
temp_bulbo.l2	11.7883	5.7724	2.042	0.04632 *
const	41.1033	87.785	0.468	0.64162

Fonte: Elaborado pelo autor (2024)

Tabela 16 - Equação do VAR: Preço vs Temp. de Bulbo (lag 3)

Estimation results for equation preco_dif2: =====				
preco_dif2 = preco_dif2.l1 + temp_bulbo.l1 + preco_dif2.l2 + temp_bulbo.l2 + preco_dif2.l3 + temp_bulbo.l3 +const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.449	0.1643	-2.733	0.00877 **
temp_bulbo.l1	-21.2391	7.031	-3.021	0.00403 **
preco_dif2.l2	-0.1466	0.1821	-0.805	0.42465
temp_bulbo.l2	26.9316	10.2929	2.617	0.01184 *
preco_dif2.l3	-0.2411	0.1735	-1.389	0.17113
temp_bulbo.l3	-11.9803	6.8419	-1.751	0.08633 .
const	137.8279	99.8634	1.38	0.17393

Fonte: Elaborado pelo autor (2024)

Tabela 17 - Equação do VAR: Preço vs Temp. de Bulbo (lag 4).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_bulbo.l1 + preco_dif2.l2 + temp_bulbo.l2 + preco_dif2.l3 + temp_bulbo.l3 + preco_dif2.l4 + temp_bulbo.l4 +const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.45751	0.17347	-2.637	0.0114 *
temp_bulbo.l1	-21.03286	7.48335	-2.811	0.0073 **
preco_dif2.l2	-0.15766	0.1901	-0.829	0.4113
temp_bulbo.l2	26.15104	11.16224	2.343	0.0236 *
preco_dif2.l3	-0.26049	0.19449	-1.339	0.1872
temp_bulbo.l3	-11.4479	11.5827	-0.988	0.3283
preco_dif2.l4	-0.07725	0.18299	-0.422	0.6749
temp_bulbo.l4	-0.45371	7.6724	-0.059	0.9531
const	148.734	124.03159	1.199	0.2367

Fonte: Elaborado pelo autor (2024)

Tabela 18 - Equação do VAR: Preço vs Temp. de Bulbo (lag 5).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_bulbo.l1 + preco_dif2.l2 + temp_bulbo.l2 + preco_dif2.l3 + temp_bu				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.4215	0.1704	-2.474	0.0175 *
temp_bulbo.l1	-15.6855	8.0423	-1.95	0.0578 .
preco_dif2.l2	-0.2362	0.1896	-1.246	0.2197
temp_bulbo.l2	22.1335	11.0383	2.005	0.0514 .
preco_dif2.l3	-0.3349	0.1926	-1.739	0.0894 .
temp_bulbo.l3	-12.2491	11.8169	-1.037	0.3059
preco_dif2.l4	-0.2326	0.1983	-1.173	0.2474
temp_bulbo.l4	-2.6915	11.5353	-0.233	0.8166
preco_dif2.l5	-0.4017	0.1836	-2.188	0.0343 *
temp_bulbo.l5	2.6291	8.0066	0.328	0.7443
const	128.1438	153.2106	0.836	0.4077

Fonte: Elaborado pelo autor (2024)

Tabela 19 - Equação do VAR: Preço vs Temp. de Bulbo (*lag* 6).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_bulbo.l1 + preco_dif2.l2 + temp_bulbo.l2 + preco_dif2.l3 + temp_bu				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.4316	0.1781	-2.4240	0.0201 *
temp_bulbo.l1	-16.7389	8.3359	-2.0080	0.0516 .
preco_dif2.l2	-0.2604	0.1939	-1.3420	0.1872
temp_bulbo.l2	20.5153	11.4129	1.7980	0.0800 .
preco_dif2.l3	-0.4015	0.2056	-1.9530	0.0580 .
temp_bulbo.l3	-11.3135	12.0492	-0.9390	0.3535
preco_dif2.l4	-0.2706	0.2093	-1.2930	0.2037
temp_bulbo.l4	-7.7274	12.3632	-0.6250	0.5356
preco_dif2.l5	-0.3765	0.2122	-1.7740	0.0838 .
temp_bulbo.l5	12.2386	11.9219	1.0270	0.3110
preco_dif2.l6	-0.1478	0.2013	-0.7340	0.4674
temp_bulbo.l6	-8.2981	8.5497	-0.9710	0.3377
const	250.2250	197.3490	1.2680	0.2123

Fonte: Elaborado pelo autor (2024)

Observando todas as equações obtidas pelo VAR, percebe-se que a variável tem impacto significativo a partir do segundo mês de defasagem. A fim de buscar mais detalhes sobre qual o melhor *lag*, foi então aplicada a decomposição da variância para cada uma das equações aprovadas no VAR. A Tabela 25, apresenta um comparativo entre os resultados obtidos para cada uma das defasagens, mostrando o quanto cada uma consegue explicar a variância da série de Preço em até 10 períodos.

Tabela 20 - Comparativo dos resultados da Decomposição da Variância: Preço vs Temp. de Bulbo.


Número de defasagens (lags)	temp_bulbo (10 passos de tempo)
1	0.0063019
2	0.0728487
3	0.1872925
4	0.1886671
5	0.1583357
6	0.1767505

Fonte: Elaborado pelo autor (2024)

Analisando os resultados obtidos, nota-se que com 3 e 4 defasagens a equação explica quase 19% da variância. Com 5 e 6 defasagens, esse valor sofre uma redução, explicando a variância em um valor próximo a 16% e 18%, respectivamente. Já o valor encontrado para 2 defasagens é mais baixo e explica aproximadamente 7% da variância do preço. Nota-se que os resultados nos testes e na decomposição da variância foram diferentes, mas optou-se pelo lag 3, pois tem o maior número de aprovações dos coeficientes das equações do VAR com um menor número de *lags*.

Foi realizada também uma análise gráfica a partir da Função de Impulso-Resposta, para verificar o comportamento da série do preço a partir do impulso aplicado. A Figura 13, apresenta graficamente os resultados da FIR para 3 defasagens.

Figura 13 - FIR: Preço vs Temperatura de Bulbo Seco (*lag 3*)



95 % Bootstrap CI, 100 runs

Fonte: Elaborado pelo autor (2024)

Analisando os gráficos, observou-se que com três lags, é possível notar que com um choque no resíduo da equação preditiva do preço do café, sob influência da temperatura do bulbo, os preços caem por até 2 meses, regredindo posteriormente ao seu preço normal (incluindo leve alta no terceiro mês futuro antes de estabilizar).

Por fim, o modelo da Temperatura de Bulbo com lag 3 foi escolhido como o que melhor explica a série do Preço, com as três defasagens aceitas na equação do VAR, uma explicação de 18,73% após 10 passos de tempo na decomposição da variância, além de apresentar um resultado estável na FIR. Assim, a Temperatura de Bulbo com três defasagens foi a variável escolhida que apresenta maior impacto no preço, ou seja, o preço atual do café sofre impacto relevante da temperatura de bulbo de três meses atrás.

4.1.1.5 Temperatura do Ponto de Orvalho

Para a Temperatura de Orvalho, com valores observados de janeiro de 2018 a dezembro de 2022, foram aplicados os testes de raiz unitária ADF e KPSS à série original e com diferenciações, e a Tabela 21 nos mostra que a Série Temporal da Temperatura de Orvalho foi originalmente reprovada, sendo necessária a aplicação de duas diferenciações para atingir estacionariedade.


Tabela 21 - Testes ADF e KPSS para Temp. de Orvalho.

Séries	Testes	
	ADF	KPSS
temp_orv	0,0100	0,2291
temp_orv_dif	0,0100	0,4180
temp_orv_dif2	0,0100	0,0496

Fonte: Elaborado pelo autor (2024)

Com valores para o p-value abaixo de 0,1 em ambos os testes, a série da Temperatura de Orvalho, com duas diferenciações, foi definida para a continuidade da análise. Assim como para as outras variáveis, foi então criada uma nova série temporal que une as duas séries a serem analisadas, possibilitando aplicar o VAR e dar sequência na identificação da melhor defasagem. A Figura 14 apresenta a nova série criada, que une o Preço e a Temperatura de Orvalho.

Figura 14 - Série Temporal do Preço com a Temp. de Orvalho.



Fonte: Elaborado pelo autor (2024)

A partir da nova série, foram aplicados os testes AIC, HQ, SC e FPE, para verificar as melhores defasagens. A Tabela 22, mostra o resultado com os melhores lags indicados por esses testes.

Tabela 22 - Testes AIC, HQ, SC e FPE para a Temp. de Orvalho.

Melhor lag para Temp_Orvalho:			
AIC(n)	HQ(n)	SC(n)	FPE(n)
1	1	1	1

Fonte: Elaborado pelo autor (2024)

Foi então rodado o modelo VAR com defasagens de 1 a 6 períodos e, para a Temperatura de Orvalho, as equações obtidas pelo modelo VAR com *lags* 1, 2 e 3, apresentaram valores aceitáveis. As Tabelas 23, 24 e 25, apresentam os resultados obtidos em para os *lags* 1, 2 e 3, respectivamente.

Tabela 23 - Equação do VAR: Preço vs Temp. de Orvalho (*lag* 1).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_orv_dif2.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2278	0.1509	-1.51	0.137
temp_orv_dif2.l1	-9.0086	3.7345	-2.412	0.0193 *
const	-0.0645	6.9647	-0.009	0.9926

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Fonte: Elaborado pelo autor (2024)

Tabela 24 - Equação do VAR: Preço vs Temp. de Orvalho (*lag* 2).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_orv_dif2.l1 + preco_dif2.l2 + temp_orv_dif2.l2 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2746	0.1583	-1.734	0.0889 .
temp_orv_dif2.l1	-8.4247	4.105	-2.052	0.0453 *
preco_dif2.l2	-0.233	0.1568	-1.486	0.1434
temp_orv_dif2.l2	-0.4374	4.2915	-0.102	0.9192
const	-0.8613	7.0873	-0.122	0.9037

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Fonte: Elaborado pelo autor (2024)

Tabela 25 - Equação do VAR: Preço vs Temp. de Orvalho (*lag* 3).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + temp_orv_dif2.l1 + preco_dif2.l2 + temp_orv_dif2.l2 + preco_dif2.l3 + temp_orv_dif2.l3 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2691	0.1615	-1.666	0.102
temp_orv_dif2.l1	-8.1246	4.5896	-1.77	0.083 .
preco_dif2.l2	-0.2297	0.1691	-1.358	0.181
temp_orv_dif2.l2	1.0233	4.8514	0.211	0.834
preco_dif2.l3	-0.1123	0.1773	-0.633	0.529
temp_orv_dif2.l3	3.3281	4.4378	0.75	0.457
const	-0.3471	7.2929	-0.048	0.962

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Fonte: Elaborado pelo autor (2024)

Observando todas as equações obtidas pelo VAR, nota-se que o VAR aplicado para uma, duas e três defasagens, apresentam equações aceitáveis, porém apenas o *lag* 1 obtém aprovação do coeficiente nos três modelos do VAR analisados. Para entender melhor o impacto em cada defasagem, foi aplicada a decomposição da variância nos modelos até três defasagens. A Tabela 26, apresenta um comparativo

entre os resultados obtidos para os *lags* 1, 2 e 3, mostrando o quanto cada uma consegue explicar a variância da série de Preço em até 10 períodos.

Tabela 26 - Decomposição da Variância: Preço vs Temp. de Orvalho (*lags* 1, 2 e 3).


Número de defasagens (lags)	temp_orvalho (10 passos de tempo)
1	0.1142393
2	0.0877524
3	0.1070563

Fonte: Elaborado pelo autor (2024)

Com os resultados obtidos para a decomposição da variância, nota-se que os valores dos três diferentes lags apresentam resultados próximos, variando entre 8,5% e 11,5%, com o menor valor sendo para o *lag* 2 e o maior para o *lag* 1.

Desta forma, com o lag 1 apresentando os melhores resultados, foi plotado o gráfico da FIR para poder realizar uma análise gráfica do impulso na série e o resultado está apresentado na Figura 15.

Figura 15 - FIR: Preço vs Temperatura de Orvalho (*lag* 1).



95 % Bootstrap CI, 100 runs

Fonte: Elaborado pelo autor (2024)

Graficamente para o lag 1, observou-se um choque no resíduo da equação preditiva do preço do café sob influência da temperatura de orvalho, pode ser observado que os preços caem por até 2 meses, regredindo posteriormente ao seu preço normal.

Por fim, o modelo da Temperatura de Orvalho com *lag* 1 foi escolhido como o que melhor explica a série do Preço, com uma defasagem aceita na equação do VAR, uma explicação de 11,4% após 10 passos de tempo na decomposição da variância, além de apresentar um impacto significativo na FIR. Desta forma, a Temperatura de Orvalho, com uma defasagem, foi a variável escolhida que apresenta maior impacto no preço. Em outras palavras, dados os resultados, o Preço sofre um impacto significativo da Temperatura de Orvalho de um mês atrás.

4.1.1.6 Umidade Relativa do Ar

Para a umidade, os testes de raiz unitária ADF e KPSS foram aplicados à série original e com diferenciações, e a Tabela 27 nos mostra que a Série Temporal da Umidade foi originalmente reprovada, sendo necessária a aplicação de duas diferenciações para atingir estacionariedade.


Tabela 27 - Testes ADF e KPSS para Umidade.

Séries	Testes	
	ADF	KPSS
umidade	0,0417	0,2440
umidade_dif	0,0100	0,5640
umidade_dif2	0,0100	0,0829

Fonte: Elaborado pelo autor (2024)

A série da Umidade, com duas diferenciações, foi definida para a continuidade da análise, após apresentar valores para o *p-value* abaixo de 0,1 em ambos os testes. Uma nova série temporal que une as duas séries a serem analisadas foi criada e, posteriormente, foi aplicado o VAR para a identificação da melhor defasagem. A Figura 16 apresenta a série criada, que une o Preço e a Umidade.

Figura 16 - Série Temporal do Preço com a Umidade.



Fonte: Elaborado pelo autor (2024)

Dando sequência ao procedimento, foram aplicados os testes AIC, HQ, SC e FPE e também aplicado o modelo VAR para as defasagens de 1 a 6, onde foi possível observar que o melhor lag para os testes é 1. No entanto, ao observar os resultados do modelo VAR, nenhuma das equações no modelo para a Umidade apresentou os *p-values*, associados ao teste de significância das variáveis do modelo, acima do valor aceitável de 0,1. A Tabela 28, mostra os resultados dos testes AIC, HQ, SC e FPE e também apresenta o resultado obtido no VAR para o lag 1.

Tabela 28 - Testes e Equação do VAR: Preço vs Umidade (lag 1).

Melhor lag para Umidade:				
	AIC(n)	HQ(n)	SC(n)	FPE(n)
	1	1	1	1
Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + umidade_dif2.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.25692	0.16122	-1.594	0.117
umidade_dif2.l1	-0.04287	0.93692	-0.046	0.964
const	0.07172	7.33001	0.01	0.992

Fonte: Elaborado pelo autor (2024)

Para agregar à análise do VAR, também foi realizada a decomposição da variância para o lag 1. A Tabela 29, apresenta os resultados obtidos.

Tabela 29 - Testes AIC, HQ, SC e FPE e Eq. do VAR: Preço vs Umidade (*lag 1*).

	\$preco_dif2	<i>lag 1</i>
	preco_dif2	umidade_dif2
[1,]	1.0000000	0.0000000
[2,]	0.9999777	0.0000223
[3,]	0.9999631	0.0000369
[4,]	0.9999571	0.0000429
[5,]	0.9999550	0.0000450
[6,]	0.9999543	0.0000457
[7,]	0.9999541	0.0000459
[8,]	0.9999540	0.0000460
[9,]	0.9999540	0.0000460
[10,]	0.9999540	0.0000460

Fonte: Elaborado pelo autor (2024)

A decomposição da variância mostrou um impacto de 0,005% da umidade no preço do café após dez passos de tempo, um valor muito baixo e que confirma que a umidade não tem impacto significativo na série temporal do preço do café.

4.1.1.7 Velocidade do Vento

Para o Vento, com valores observados de janeiro de 2018 a dezembro de 2022, foram aplicados os testes de raiz unitária ADF e KPSS à série original e com diferenciações, e a Tabela 30 nos mostra que a Série Temporal do Vento foi originalmente reprovada, sendo necessária a aplicação de uma diferenciação para atingir estacionariedade.


Tabela 30 - Testes ADF e KPSS para o Vento.

Séries	Testes	
	ADF	KPSS
vento	0,0100	0,5401
vento_dif	0,0100	0,0430
vento_dif2	0,0100	0,0749

Fonte: Elaborado pelo autor (2024)

A série do Vento, com uma diferenciação, foi definida para a continuidade da análise, após apresentar valores para o *p-value* abaixo de 0,1 em ambos os testes. Uma nova série temporal que une as duas séries a serem analisadas foi criada e, posteriormente, foi aplicado o VAR para a identificação da melhor defasagem. A Figura 17 apresenta a nova série criada, que une o Preço e o Vento.

Figura 17 - Série Temporal do Preço com o Vento.



Fonte: Elaborado pelo autor (2024)

Os testes AIC, HQ, SC e FPE foram aplicados a essa nova série, para verificar as melhores defasagens. A Tabela 31, mostra o resultado com os melhores *lags* indicados por esses testes.

Tabela 31 - Testes AIC, HQ, SC e FPE para o Vento.

Melhor lag para Vento:			
AIC(n)	HQ(n)	SC(n)	FPE(n)
1	1	1	1

Fonte: Elaborado pelo autor (2024)

Foi então aplicado o modelo VAR para os *lags* de 1 a 6 e constatou-se que apenas a equação para *lag 2* obteve valores aceitáveis, apresentando valores abaixo no nível de significância. Para *lag 3*, a equação apresentou um valor bem próximo ao nível de significância e, por isso, ele seguiu sendo utilizado na sequência da análise. A Tabela 32 mostra o resultado obtido para o *lag 1*, que em um primeiro momento foi sugerido pelos testes AIC, HQ, SC e FPE. Já a Tabela 33 e a Tabela 34, apresentam os resultados para *lag 2* e *lag 3*, respectivamente.

Tabela 32 - Equação do VAR:Preço vs Vento (*lag 1*).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + vento_dif.l1 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.2597	0.158	-1.644	0.106
vento_dif.l1	-15.9553	34.6132	-0.461	0.647
const	0.1244	7.3167	0.017	0.986

Fonte: Elaborado pelo autor (2024)

Tabela 33 - Equação do VAR de Preço vs Vento (*lag 2*).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + vento_dif.l1 + preco_dif2.l2 + vento_dif.l2 + const				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.3092	0.1563	-1.978	0.0534 .
vento_dif.l1	-7.0531	35.4251	-0.199	0.843
preco_dif2.l2	-0.2788	0.1641	-1.699	0.0953 .
vento_dif.l2	-58.9409	34.1712	-1.725	0.0906 .
const	-0.469	7.213	-0.065	0.9484

Fonte: Elaborado pelo autor (2024)

Tabela 34 - Equação do VAR de Preço vs Vento (*lag* 3).

Estimation results for equation preco_dif2:				
=====				
preco_dif2 = preco_dif2.l1 + vento_dif.l1 + preco_dif2.l2 + vento_dif.l2 + preco_dif2.l3 + vento_dif				
	Estimate	Std. Error	t value	Pr(> t)
preco_dif2.l1	-0.3361	0.1629	-2.063	0.0445 *
vento_dif.l1	-9.9538	36.6786	-0.271	0.7873
preco_dif2.l2	-0.3056	0.1731	-1.765	0.0839 .
vento_dif.l2	-58.1885	36.6647	-1.587	0.1191
preco_dif2.l3	-0.1033	0.1816	-0.569	0.5721
vento_dif.l3	-28.1385	36.2405	-0.776	0.4413
const	-0.3216	7.4516	-0.043	0.9658

Fonte: Elaborado pelo autor (2024)


A fim de embasar a definição da melhor defasagem, foi aplicada a decomposição da variância para os *lags* 1, 2 e 3. A Tabela 48, apresenta um comparativo entre os resultados obtidos para essas defasagens, mostrando o quanto cada uma consegue explicar a variância da série de Preço em até 10 períodos.

Tabela 35 - Decomposição da Variância: Preço vs Vento (*lags* 1,2 e 3).

Número de defasagens (lags)	vento_dif (10 passos de tempo)
1	0.0038557
2	0.0545757
3	0.0510701

Fonte: Elaborado pelo autor (2024)

Observando a decomposição da variância, conclui-se que *lag* 1 explica aproximadamente 0,4%, um valor baixo se comparado aos outros dois resultados. Para *lag* 2 e 3, os valores foram similares, aproximando dos 5% de explicação da variância do preço após dez passos de tempo. Como os resultados para *lag* 2 estavam sendo aceitáveis, optou-se por analisar a Função Impulso-Resposta para essa defasagem. A Figura 18 apresenta a FIR para a série do vento com duas defasagens.

Figura 18 - FIR: Preço vs Vento (*lag 2*).

95 % Bootstrap CI, 100 runs

Fonte: Elaborado pelo autor (2024)

4.1.2 Resultados da análise contemporânea das variáveis

Em um segundo momento, optou-se por verificar também a relação entre as variáveis sem nenhum tipo de defasagem. A análise foi feita com as variáveis contemporâneas, utilizando as séries temporais sem nenhuma diferenciação, aplicando a Regressão Linear Múltipla, a seleção *Stepwise* e, por fim, a Regressão Linear Simples para analisar melhor os resultados de cada uma das variáveis.

4.1.2.1 Regressão Linear Múltipla

Realizando a Regressão Linear Múltipla, onde todas as variáveis independentes foram utilizadas para entender seu impacto no preço, foi possível notar que, para esse método, o vento foi a única variável com bons resultados, apresentando um *p-value* abaixo do aceitável de 0,1. A Tabela 36, mostra os resultados obtidos diretamente na Regressão Linear Múltipla.

Tabela 36 - Regressão Linear Múltipla.

Regressão Linear Múltipla				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-104.0287	9978.5351	-0.010	0.9917
precip	0.2285	0.6906	0.331	0.7421
pressao	-0.0154	10.1391	-0.002	0.9988
radiacao	-0.3888	0.3607	-1.078	0.2861
temp_bulbo	-18.0193	107.3522	-0.168	0.8674
temp_orv	16.8214	109.3938	0.154	0.8784
umidade	-1.3258	26.4241	-0.050	0.9602
vento	900.9676	219.1822	4.111	0.0001 ***
Residual standard error: 302.2 on 52 degrees of freedom				
Multiple R-squared: 0.2956, Adjusted R-squared: 0.2008				
F-statistic: 3.117 on 7 and 52 DF, p-value: 0.008005				

Fonte: Elaborado pelo autor (2024)

Também foi rodado o modelo *Stepwise* para verificar se alguma das variáveis passaria. Como esperado, o modelo aprovou no final, apenas a variável vento, com um *p-value* de 0,000069. A Tabela 37 apresenta os resultados da seleção *Stepwise*.

Tabela 37 – Seleção *Stepwise*.

Seleção Stepwise								
Deleted	Chi-Sq	d.f.	P	Residual	d.f.	P	AIC	R2
pressao	0	1	0.9988	0	1	0.9988	-2	0.296
umidade	0	1	0.9595	0	2	0.9987	-4	0.296
temp_bulbo	0.04	1	0.837	0.04	3	0.9975	-5.96	0.295
temp_orv	0.01	1	0.9203	0.05	4	0.9996	-7.95	0.295
precip	0.4	1	0.5283	0.45	5	0.9938	-9.55	0.289
radiacao	5.53	1	0.0187	5.98	6	0.4253	-6.02	0.215
Approximate Estimates after Deleting Factors								
	Coef	S.E.	Wald Z	P				
Intercept	-492.3	296.4	-1.661	0.096700				
vento	696.3	174.9	3.980	0.000069				
Factors in Final Model								
[1] vento								

Fonte: Elaborado pelo autor (2024)

De todas as sete variáveis independentes analisadas na regressão linear múltipla e na seleção *stepwise*, apenas o vento obteve um *p-value* abaixo do valor aceitável de 0,1. Assim, para a análise contemporânea, pode-se afirmar que apenas o vento causa um impacto significativo no preço do café. Ao analisar os impactos com defasagem, notamos que o vento obteve valores próximos de uma aprovação para *lags* 1, 2 e 3, mas foi na análise contemporânea, ou seja, sem defasagem que ele apresentou um impacto significativo.


Na análise de regressões lineares, é importante verificar a normalização dos resíduos. Para garantir a normalização foi realizado o teste de Shapiro-Wilk, onde o *p-value* obtido é de 0,04302. Este valor, está acima de 1% e comprova a normalidade dos resíduos. O resultado pode ser analisado na Tabela 38 e a distribuição dos resíduos pode ser observada na Figura 19.

Tabela 38 – Teste de Normalidade – Shapiro-Wilk.

Shapiro-Wilk normality test	
W = 0.9592	p-value = 0.04302

Fonte: Elaborado pelo autor (2024)

Figura 19 – Resíduos da Regressão Linear.



Fonte: Elaborado pelo autor (2024)

Por fim, para observar melhor os impactos contemporâneos de cada variável em relação ao preço, foi também realizada uma análise a partir da regressão linear simples para cada variável.

4.1.2.2 Regressão Linear Simples

Observando as interações de cada variável com o preço, individualmente, os resultados também não foram aceitáveis. A Regressão Linear Simples também mostrou que não há causalidade contemporânea para essas variáveis em relação ao preço do café. As Tabelas 39, 40, 41, 42, 43, 44 e 45 apresentam os resultados obtidos para a Regressão Linear Simples.

Tabela 39 - Regressão Linear Simples: Precipitação.

Regressão Linear Simples - Precipitação				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	690.1745	65.8418	10.480	0.0000 ***
precip	-0.1272	0.4704	-0.270	0.7880
Residual standard error: 340.7 on 58 degrees of freedom				
Multiple R-squared: 0.00126, Adjusted R-squared: -0.01596				
F-statistic: 0.07316 on 1 and 58 DF, p-value: 0.7878				

Fonte: Elaborado pelo autor (2024)

Tabela 40 - Regressão Linear Simples: Pressão.

Regressão Linear Simples - Pressão				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	2066.4440	9062.6910	0.228	0.8200
pressao	-1.4350	9.3580	-0.153	0.8790
Residual standard error: 340.8 on 58 degrees of freedom				
Multiple R-squared: 0.0004052, Adjusted R-squared: -0.01683				
F-statistic: 0.02351 on 1 and 58 DF, p-value: 0.8787				

Fonte: Elaborado pelo autor (2024)

Tabela 41 - Regressão Linear Simples: Radiação.

Regressão Linear Simples - Radiação				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	867.7320	268.7200	3.229	0.0021 **
radiacao	-0.1410	0.1960	-0.720	0.4746
Residual standard error: 339.4 on 58 degrees of freedom				
Multiple R-squared: 0.008852, Adjusted R-squared: -0.008237				
F-statistic: 0.518 on 1 and 58 DF, p-value: 0.4746				

Fonte: Elaborado pelo autor (2024)

Tabela 42 - Regressão Linear Simples: Temp. de Bulbo.

Regressão Linear Simples - Temperatura de Bulbo				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1162.0800	493.0300	2.357	0.0218 *
temp_bulbo	-21.9000	22.1700	-0.988	0.3273
Residual standard error: 338.1 on 58 degrees of freedom				
Multiple R-squared: 0.01655, Adjusted R-squared: -0.0004073				
F-statistic: 0.976 on 1 and 58 DF, p-value: 0.3273				

Fonte: Elaborado pelo autor (2024)

Tabela 43 - Regressão Linear Simples: Temp.de Orvalho.

Regressão Linear Simples - Temperatura de Orvalho				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1095.3300	321.3100	3.409	0.0012 **
temp_orv	-24.9700	19.0000	-1.314	0.1940
Residual standard error: 335.9 on 58 degrees of freedom				
Multiple R-squared: 0.02892, Adjusted R-squared: 0.01217				
F-statistic: 1.727 on 1 and 58 DF, p-value: 0.1939				

Fonte: Elaborado pelo autor (2024)

Tabela 44 - Regressão Linear Simples: Umidade.

Regressão Linear Simples - Umidade				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1048.4420	611.3820	1.715	0.0917
umidade	-5.0470	8.2850	-0.609	0.5447
Residual standard error: 339.8 on 58 degrees of freedom				
Multiple R-squared: 0.006359, Adjusted R-squared: -0.01077				
F-statistic: 0.3712 on 1 and 58 DF, p-value: 0.5447				

Fonte: Elaborado pelo autor (2024)

Tabela 45 - Regressão Linear Simples: Vento.

Regressão Linear Simples - Vento				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-492.3000	296.3000	-1.661	0.1020
vento	696.3000	174.9000	3.980	0.0002 ***
Residual standard error: 302.1 on 58 degrees of freedom				
Multiple R-squared: 0.2146, Adjusted R-squared: 0.201				
F-statistic: 15.84 on 1 and 58 DF, p-value: 0.0001938				

Fonte: Elaborado pelo autor (2024)

Os resultados obtidos através da Regressão Linear Simples, corroboram com os resultados obtidos na regressão simples e reafirmam que apenas o vento impacta no preço do café em uma análise contemporânea. Pode ser observado que os valores encontrados de R^2 para todas as outras variáveis são pouco significativos e nenhuma delas variáveis apresentou um *p-value* abaixo de 0,1.

4.1.3 Considerações Finais sobre os Resultados

Os resultados mostram a importância de defasagens temporais na relação entre variáveis climáticas e preço do café, em especial para a temperatura de bulbo seco e do ponto de orvalho. Variáveis como precipitação, pressão e radiação global, apesar de esperadas como influentes, não apresentaram impacto significativo no período analisado.

Essas informações são valiosas para produtores e gestores, indicando que decisões relacionadas à produção do café devem considerar períodos de atraso entre eventos climáticos e os seus reflexos no mercado. A ausência de causalidade contemporânea reforça a necessidade de modelos preditivos que incorporem *lags* temporais para maior precisão.

A Tabela 46 mostra um resumo com os resultados das variáveis, os melhores *lags* escolhidos e o impacto de cada uma, obtido pela decomposição da variância.

Tabela 46 – Resumo dos resultados obtidos.

Variável independente	Impacto contemporâneo (Reg. Linear)	Impacto defasado (VAR)	Melhor defasagem	Explicação na Decomposição da Variância
Precipitação	Não identificado	Não identificado	-	-
Pressão	Não identificado	Não identificado	-	-
Radiação	Não identificado	Não identificado	-	-
Temperatura de Bulbo Seco	Não identificado	Sim	3	18.73%
Temperatura do ponto de Orvalho	Não identificado	Sim	1	11.42%
Umidade Relativa do Ar	Não identificado	Não identificado	-	-
Velocidade do Vento	Sim	Sim	2	5,46%

Fonte: Elaborado pelo autor (2024)

Portanto, o que se tem é que a Temperatura de Bulbo Seco impacta o valor do preço do café em até 18,73% para uma defasagem de três períodos. A Temperatura do ponto de Orvalho pode impactar até 11,42% no preço do café com a defasagem de um período. E a Velocidade do Vento, é a única variável que tem um impacto contemporâneo na precificação do café.

5 CONCLUSÃO

O objetivo deste trabalho foi analisar como as variáveis climáticas afetam o preço do café arábica no estado do Espírito Santo, usando dados de 2018 a 2022. Para isso, foram utilizadas técnicas como Regressão Linear, VAR, Decomposição da Variância, Causalidade de Granger e Função Impulso-Resposta para estudar as relações entre as variáveis climáticas e o preço do café.

Os resultados mostraram que, na análise defasada, algumas variáveis climáticas, como a precipitação, a pressão atmosférica, a radiação e a umidade não têm um impacto significativo no preço do café. Isso ficou claro tanto nas análises do VAR quanto na decomposição da variância, que não apontaram nenhuma causalidade relevante entre essas variáveis e o preço.

Por outro lado, a temperatura de bulbo se destacou como uma variável importante. O VAR mostrou que ela tem um impacto significativo nas defasagens de 2 a 6 meses e que para 3 defasagens todas as equações eram aprovadas, mostrando-se a melhor defasagem que causa impacto no preço do café. A decomposição da variância confirmou o resultado do VAR e mostrou que o *lag* 3 explica cerca de 19% da variação do preço. A temperatura de orvalho também apresentou resultados significativos, especialmente para o *lag* 1, onde o p-value foi de 0.0175, indicando que essa variável realmente afeta o preço do café nesse período. Em sua decomposição da variância, pode-se observar que o impacto chega a mais de 11% na precificação do café para uma defasagem.

O vento teve um impacto mais claro no *lag* 2, com uma explicação de cerca de 5% na decomposição da variância. A Função Impulso-Resposta confirmou que há um impacto, em que o preço sobe nos 2 primeiros meses e depois tende a se estabilizar. No entanto, nota-se que o vento tem menos da metade do impacto das outras variáveis aprovadas na análise defasada.

Nas análises de regressão múltipla e linear, verificou-se que apenas o vento apresentou uma relação contemporânea significativa com o preço do café, enquanto as demais variáveis climáticas não mostraram impacto relevante no mesmo período. Esse resultado destaca o papel específico do vento no curto prazo, sugerindo que o impacto das outras variáveis climáticas sobre o preço do café tende a ocorrer com defasagens temporais.

Por fim, com todas as análises realizadas, foi possível atender todos os objetivos do presente estudo. Este trabalho apresentou algumas limitações importantes que devem ser consideradas. Primeiramente, a análise focou exclusivamente nas variáveis climáticas, desconsiderando fatores socioeconômicos que também afetam significativamente o preço do café, como os impactos da pandemia e os cenários de guerra recentes. Além disso, os dados utilizados abrangeram apenas os anos de 2018 a 2022, o que pode ter restringido a capacidade de capturar tendências de longo prazo ou variações decorrentes de eventos históricos anteriores. Como sugestões para trabalhos futuros, seria interessante incluir variáveis socioeconômicas no modelo, permitindo uma análise mais abrangente do comportamento do preço do café. Recomenda-se, também, expandir o período analisado e o número de cidades incluídas no estudo, o que pode aumentar a precisão dos resultados e possibilitar uma compreensão mais detalhada das dinâmicas regionais e climáticas no estado do Espírito Santo.

REFERÊNCIAS

Agrolink. **Preços do café arábica**. Disponível em: <https://www.agrolink.com.br>. Acesso em: 12 de agosto 2023.

ABIC - Associação Brasileira da Indústria do Café. **Relatório sobre o consumo de café no Brasil**. 2021. Disponível em: <https://estatisticas.abic.com.br/estatisticas/indicadores-da-industria/>. Acesso em: 10 de outubro de 2024.

ABEPRO. ABEPRO - Associação Brasileira de Engenharia de Produção | **A Profissão**. Disponível em: <https://portal.abepro.org.br/profissao/>. Acesso em: 14 de julho de 2022.

AIUBE, Fernando Antonio Lucena. **Econometria para Séries Financeiras**. Rio de Janeiro: PUCRIO, 2007.

BERTOLO, L. P. **Introdução às Séries Temporais**. Rio de Janeiro: Elsevier, 2012.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time Series Analysis: Forecasting and Control**. 5th ed. Hoboken: Wiley, 2015.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **PIB do agronegócio brasileiro**. 2020. Disponível em: <http://www.cepea.esalq.usp.br>. Acesso em: 12 de setembro de 2024.

CNA. CNA - Confederação da Agricultura e Pecuária do Brasil | **Panorama do Agro**. Disponível em: <https://cnabrasil.org.br/cna/panorama-do-agro/>. Acesso em: 15 de julho de 2022.

EMBRAPA. **Produção de café no Brasil**. 2022. Disponível em: <https://www.embrapa.br/cafe/busca-de-noticias/-/noticia/77216868/safra-dos-cafes-do-brasil-totaliza-5092-milhoes-de-sacas-de-60kg-de-cafe-em-2022>. Acesso em: 12 de março de 2024.

ENDERS, W. **Applied Econometric Time Series**. 4th ed. Hoboken: Wiley, 2014.

EXAME. **Preço do café atinge maior alta em 7 anos devido a geadas e seca**. 2022. Disponível em: <https://exame.com/agro/preco-do-cafe-bate-recorde-dos-ultimos-7-anos-entenda/>. Acesso em: 15 de agosto 2024.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: AMGH, 2009.

GUEDES, Ítalo M. R. **Mudanças Climáticas Globais e a Produção de Hortaliças**. Embrapa Hortaliças. Brasília, 2009.

HAMILTON, J. D. *Time Series Analysis*. Princeton: Princeton University Press, 1994.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 2nd ed. Melbourne: OTexts, 2018.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Dados sobre consumo e produção de café no Brasil**. 2020. Disponível em: <https://www.ibge.gov.br/explica/producao-agropecuaria/cafe/br>. Acesso em: 9 de outubro de 2023.

INCAPER - Instituto Capixaba de Pesquisa, Assistência Técnica e Extensão Rural. **Dados sobre a cafeicultura no Espírito Santo**. 2021. Disponível em: <https://incaper.es.gov.br/cafeicultura>. Acesso em: 15 de maio de 2024.

INMET - Instituto Nacional de Meteorologia. **Relatórios climáticos do Brasil**. 2021. Disponível em: <https://www.inmet.gov.br>. Acesso em: 2 de outubro de 2023.

IPCC. **Relatório sobre mudanças climáticas e impactos globais**. 2022. Disponível em: <https://www.ipcc.ch>. Acesso em: 28 de maio de 2023.

LÜTKEPOHL, H. **New Introduction to Multiple Time Series Analysis**. Berlin: Springer, 2005.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting Methods and Applications**. 3rd ed. New York: Wiley, 1998.

Ministério da Agricultura, Pecuária e Abastecimento (MAPA). **Relatórios sobre produção agrícola no Brasil**. 2018. Disponível em: https://www.gov.br/agricultura/pt-br/canais_atendimento/ouvidoria/relatorios. Acesso em: 25 de agosto de 2023.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. 5th ed. New York: Wiley, 2009.

MORETTIN, P.A. **Econometria financeira: um curso em séries temporais financeiras**. São Paulo: E. Blucher, 2008.

OIC - Organização Internacional do Café. **Relatórios anuais sobre o mercado global de café**. 2021. Disponível em: <https://ico.org/pt/resources/coffee-market-report-statistics-section/>. Acesso em: 18 de setembro de 2024.

PINDYCK, R.S.; RUBINFELD, D.L. **Econometria: modelos e previsões**. 4. ed. Rio de Janeiro: Campus, 2004.

GRÜTE, R; TRACHSEL, T.; LAUBE, P; JAISLI I. **Expected global suitability of coffee, cashew and avocado due to climate change**. 2022. PLoS ONE 17(1): e0261976. Disponível em: <https://doi.org/10.1371/journal.pone.0261976>. Acesso em 15 de dezembro de 2024.