



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA RURAL

CARLOS ALBERTO BRASIL SOBRINHO

EFEITOS DO FENÔMENO EL NIÑO SOBRE O DESEMPENHO DO
AGRONEGÓCIO BRASILEIRO: ANÁLISE COM BASE NO ÍNDICE IBOAGRO

FORTALEZA

2026

CARLOS ALBERTO BRASIL SOBRINHO

EFEITOS DO FENÔMENO EL NIÑO SOBRE O DESEMPENHO DO AGRONEGÓCIO
BRASILEIRO: ANÁLISE COM BASE NO ÍNDICE IBOAGRO

Dissertação apresentada à Coordenação do Programa de Pós-Graduação em Economia Rural da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre, Área de concentração: Economia Aplicada ao Agronegócio.

Orientador: Prof. Dr. José Newton Pires Reis

FORTALEZA

2026

CARLOS ALBERTO BRASIL SOBRINHO

EFEITOS DO FENÔMENO EL NIÑO SOBRE O DESEMPENHO DO AGRONEGÓCIO
BRASILEIRO: ANÁLISE COM BASE NO ÍNDICE IBOAGRO

Dissertação apresentada à Coordenação do Programa de Pós-Graduação em Economia Rural da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre - Área de concentração: Economia Aplicada ao Agronegócio.

Orientador: Prof. Dr. José Newton Pires Reis

Aprovada em: 27/01/2026.

BANCA EXAMINADORA

Prof. Dr. José Newton Pires Reis (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. José de Jesus Sousa Lemos
Universidade Federal do Ceará (UFC)

Prof. Dr. Espedito Cezario Martins
Universidade Estadual Vale do Acaraú (UVA)

A Deus.

Aos meus pais, Lenilda e Pedro, minha filha, Ana Gabriela, e aos meus mestres, que iluminaram o caminho do conhecimento e inspiraram o estabelecimento desta trajetória acadêmica.

AGRADECIMENTOS

A Deus, pela força, proteção e serenidade que me acompanharam à extensão desta jornada acadêmica.

À minha família, pelo apoio incondicional, compreensão e incentivo permanente, que tornaram possível a conclusão desta etapa tão significativa da minha formação.

Ao meu orientador, Professor Doutor José Newton, pela dedicação, paciência, rigor científico, bem assim pelas contribuições essenciais para o desenvolvimento deste trabalho. A sua orientação foi determinante para o amadurecimento acadêmico e intelectual alcançado nesta pesquisa. Aos professores doutores José Lemos e Espedito Cezario, membros da Banca Examinadora, pelas valiosas contribuições, sugestões criteriosas e disponibilidade em avaliar esta Dissertação, colaborando significativamente para o seu aprimoramento acadêmico.

Aos docentes do Programa de Pós-Graduação em Economia Rural – PPGER, pelas aulas, debates, críticas e sugestões que contribuíram de maneira substantiva para a qualidade do estudo.

Aos colegas de turma e amigos conquistados no percurso, pelo companheirismo, trocas intelectuais e apoio mútuo que fortaleceram esta caminhada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Capes, pelo apoio financeiro concedido.

A todos os que, direta ou indiretamente, concorreram para elaboração deste trabalho, expresso minha sincera gratidão.

“A incerteza não é apenas uma imperfeição do conhecimento; é uma característica essencial da vida econômica.”

Frank H. Knight, 1921.

RESUMO

Analisa os efeitos do fenômeno El Niño sobre o desempenho econômico-financeiro do agronegócio brasileiro no período de 1968 a 2024, com suporte na elaboração e aplicação de um índice setorial específico denominado IboAgro. O objetivo central consiste em avaliar, integradamente, o modo como choques climáticos globais associados ao El Niño e variações regionais de precipitação afetam a dinâmica financeira das principais empresas do agronegócio listadas na bolsa de valores brasileira. Com tal intenção, o trabalho propõe o cálculo do IboAgro com base na metodologia do Ibovespa, adaptada para refletir exclusivamente o comportamento de empresas dos segmentos agrícola, pecuário e agroindustrial, com critérios consistentes de inclusão e permanência, assegurando maior estabilidade e representatividade setorial à proporção do tempo. A abordagem empírica adota uma estratégia econométrica quantitativa, utilizando modelos com erros consistentes à heterocedasticidade e à autocorrelação, além de arranjos analíticos dinâmicos que incorporam o *Oceanic Niño Index* (ONI) como medida de intensidade do fenômeno El Niño e variáveis de precipitação média anual por macrorregião brasileira como canais de transmissão climática. Adicionalmente, são exploradas assimetrias climáticas entre episódios de El Niño e La Niña, bem como procedimentos de redução de multicolinearidade por meio da Análise de Componentes Principais. Os resultados indicam que choques positivos associados ao El Niño exercem influxos negativos contemporâneos e persistentes sobre o desempenho do IboAgro, evidenciando elevada sensibilidade climática do setor. Observa-se, ainda, assimetria relevante nos efeitos climáticos, com impactos mais intensos durante episódios de El Niño em comparação a choques de sinais opostos. As precipitações regionais, especialmente nas regiões Nordeste e Sudeste, revelam-se canais centrais de transmissão desses choques, associando-se a reduções estatisticamente significativas no desempenho agregado do agronegócio brasileiro. Tais evidências são consistentes com a literatura nacional e internacional, que destaca a vulnerabilidade do setor agropecuário a eventos climáticos extremos e à intensificação da variabilidade hidrológica. Conclui-se que o IboAgro constitui um instrumento analítico consistente e adequado para monitorar a resposta do agronegócio brasileiro aos choques climáticos, oferecendo subsídios relevantes para a gestão de riscos, a formulação de políticas públicas e o planejamento estratégico das empresas perante os desafios impostos pelas mudanças climáticas.

Palavras-chave: El Niño; agronegócio brasileiro; variabilidade climática; risco climático; Modelos GVAR.

ABSTRACT

This study analyzes the effects of El Niño characteristics on the economic and financial performance of Brazilian agribusiness from 1968 to 2024, through the construction and application of a specific sectoral index called IboAgro. The central objective is to evaluate, in an integrated way, how global climate shocks associated with El Niño and regional variations in specialization are related to the financial dynamics of the main agribusiness companies specific to the Brazilian stock exchange. To this end, the work proposes the calculation of IboAgro based on the IBOVESPA methodology, adapted to exclusively reflect the behavior of companies in the agricultural, livestock, and agro-industrial segments, with consistent inclusion and permanence criteria, ensuring greater stability and sectoral representativeness over time. The empirical approach adopts a quantitative econometric strategy, using models with errors consistent with heteroscedasticity and autocorrelation, as well as dynamic analytical arrangements that incorporate the Oceanic Niño Index (ONI) as a measure of the intensity of the El Niño phenomenon and variations in average annual variations by Brazilian macro-region as channels of climate transmission. Furthermore, climatic asymmetries between El Niño and La Niña episodes are explored, as well as procedures for reducing multicollinearity through Principal Component Analysis. The results indicate that positive shocks associated with El Niño exert contemporaneous and persistent negative impacts on the performance of the IboAgro index, highlighting the sector's high climate sensitivity. Furthermore, a relevant asymmetry in climatic effects is observed, with more intense impacts during El Niño episodes compared to shocks of the opposite sign. Regional rainfall, especially in the Northeast and Southeast regions, reveals itself as a central channel for the transmission of these shocks, being associated with statistically significant reductions in the aggregate performance of Brazilian agribusiness. This evidence is consistent with national and international literature, which highlights the vulnerability of the agricultural sector to extreme climatic events and the intensification of hydrological variability. It is concluded that the IboAgro constitutes a consistent and adequate analytical instrument for monitoring the response of Brazilian agribusiness to climate shocks, offering relevant support for risk management, the formulation of public policies, and the strategic planning of companies in the face of the challenges posed by climate change.

Keywords: El Niño; brazilian agribusiness; climate variability; climate risk; GVAR models.

LISTA DE FIGURAS

Figura 1 – Efeitos do El Niño no clima mundial	18
Figura 2 – Funcionamento da circulação atmosférica e oceânica no Pacífico Equatorial em anos normais e durante o fenômeno El Niño	20

LISTA DE GRÁFICOS

Gráfico 1 – Evolução do ONI e classificação dos regimes ENSO	21
Gráfico 2 – Evolução do IboAgro em nível no Brasil (1968-2024	56
Gráfico 3 – Retorno do IboAgro ($\Delta \ln$)	56
Gráfico 4 – ONI por ano, com classificação ENSO (El Niño / La Niña / Neutro)	57
Gráfico 5 – IboAgro (linha) e ONI (barras)	58
Gráfico 6 – Precipitação média anual, conforme a região	58
Gráfico 7 – Dispersão: $\Delta \ln(IboAgro)$ vs ONI (com tendência linear)	60
Gráfico 8 – Predição marginal: $\Delta \ln(IboAgro)$ vs ONI (Arranjo Analítico 1, HAC)	61
Gráfico 9 – Resíduos à proporção do tempo (Arranjo Analítico 1)	61
Gráfico 10– ONI vs precipitação, conforme a região. Centro-Oeste.	63
Gráfico 11– ONI vs precipitação, conforme a região. Nordeste.	63
Gráfico 12– ONI vs precipitação, conforme a região. Norte	64
Gráfico 13– ONI vs precipitação, conforme a região. Sudeste	64
Gráfico 14– ONI vs precipitação, conforme a região. Sul	64
Gráfico 15– PCA: variância explicada	66
Gráfico 16– Predição marginal: $\Delta \ln(IboAgro)$ vs ONI (Arranjo Analítico 3)	69

LISTA DE TABELAS

Tabela 1 – Estimação do impacto do fenômeno El Niño e da precipitação regional sobre a variação do índice IboAgro (Arranjo Analítico 1 – erros-padrão HAC/Newey-West).	59
Tabela 2 Arranjo Analítico 2 (HAC/Newey-West): Resultados da regressão $\Delta \ln(IboAgro)$ com correção HAC (Newey-West).	62
Tabela 3 – PCA do clima: proporção da variância explicada	67
Tabela 4 – PCA do clima: <i>loadings</i> do primeiro componente principal (PC1)	67
Tabela 5 – Estimação do Arranjo Analítico 3: impacto do ONI e do fator climático agregado (PC1) sobre a variação logarítmica do índice IboAgro (HAC/Newey-West).	59
Tabela 6 – Comparação de ajuste e critérios de informação (Arranjos Analíticos 1, 2 e 3)	62

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ACP	Análise de Componente Principais
AIC	<i>Akaike Information Criterion</i> (Critério de Informação de Akaike)
B3	Brasil, Bolsa, Balcão
BIC	<i>Bayesian Information Criterion</i> (Critério de Informação Bayesiano)
Capes	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
Cepe	Centro de Estudos Avançados em Economia Aplicada
CNA	Confederação da Agricultura e Pecuária do Brasil
DVEP	Decomposição da Variância do Erro de Previsão
ENSO	<i>El Niño-Southern Oscillation</i> (El Niño-Oscilação Sul)
FIR	Funções Impulso-Resposta
GA	Giro do Ativo
GVAR	<i>Global Vector Autoregressive Model</i> (Modelo Global de Vetores Autorregressivos)
HAC	<i>Heteroskedasticity and Autocorrelation Consistent</i> (Heterocedasticidade e Autocorrelação consistentes)
HQ	<i>Hannan-Quinn Information Criterion</i> (Critério de Informação de Hannan-Quinn)
IBGE	Instituto Brasileiro de Geografia e Estatística
Ibovespa	Índice Bovespa
IboAgro	Índice do Agronegócio Brasileiro
ILPF	Integração Lavoura-Pecuária-Floresta
IN	Índice de Negociabilidade
Inmet	Instituto Nacional de Meteorologia
IPCA	Índice Nacional de Preços ao Consumidor Amplo
IPCC	<i>Intergovernmental Panel on Climate Change</i> (Painel Intergovernamental sobre Mudanças Climáticas)
IPL	Imobilização do Patrimônio Líquido
LC	Liquidez Corrente
LI	Liquidez Imediata
LS	Liquidez Seca

Mapa	Ministério da Agricultura, Pecuária e Abastecimento
NOAA	<i>National Oceanic and Atmospheric Administration</i> (Administração Nacional Oceânica e Atmosférica)
ONI	<i>Oceanic Niño Index</i> (Índice Oceânico Niño)
PCA	Participação de Capitais de Terceiros
ROA	Return on Assets (Retorno sobre Ativos)
ROE	Return on Equity (Retorno sobre o Patrimônio Líquido)
VAR	<i>Vector Autoregressive Model</i> (Modelo Autorregressivo Vetorial)
VARX	<i>Vector Autoregressive Model with Exogenous Variables</i> (Modelo Autorregressivo Vetori com Variáveis exógenas)

LISTA DE SÍMBOLOS

Δ	Varição ou diferença entre dois períodos consecutivos
\ln	Logaritmo natural
Y	Variável dependente
X	Variável independente
β	Coefficiente associado às variáveis explicativas nos modelos econométricos
ε_t	Termo de erro aleatório no período t
t	Período (ou tempo)
$t - 1$	Defasagem temporal de uma unidade
R^2	Coefficiente de determinação
\bar{R}^2	Coefficiente de determinação ajustado
p	Valor-p (nível de significância estatística)
λ	Autovalor associado ao sistema dinâmico
$I(0)$	Série estacionária em nível
$I(1)$	Série integrada de ordem um
μ	Termo constante (intercepto)
Σ	Matriz de variância-covariância
$\Phi(L)$	Polinômio no operador defasagem
L	Operador defasagem
ω_{ij}	Peso de ponderação da empresa ou unidade j sobre a unidade i
PC_1	Primeiro componente principal da Análise de Componentes Principais
%	Porcentagem
Mm	Milímetros (unidade de precipitação)
°C	Graus Celsius (unidade de temperatura)
\$	Dólar americano

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	16
3	REVISÃO DE LITERATURA	18
3.1	Fenômeno El Niño	18
3.1.1	<i>El Niño e seus Impactos Climáticos</i>	21
3.1.2	<i>Efeitos do El Niño na Agricultura Brasileira</i>	24
3.1.3	<i>Impactos do El Niño na Rentabilidade das Empresas do Agronegócio</i>	25
3.1.4	<i>Transmissão de Impactos Climáticos</i>	28
3.1.5	<i>Considerações sobre a Resiliência e Adaptação das Empresas do Agronegócio</i>	30
3.2	O Índice Bovespa e a participação das empresas do agronegócio	32
4	METODOLOGIA	35
4.1	Abordagem geral da pesquisa	35
4.2	Delimitação temporal e amostral	35
4.3	Variáveis do estudo e indicadores de desempenho econômico	36
4.3.1	<i>Justificativa para a exclusão das variáveis de temperatura regional</i>	38
4.3.2	<i>Especificação do cálculo do índice IboAgro</i>	39
4.3.3	<i>Tratamento da assimetria climática do fenômeno El Niño</i>	42
4.3.4	<i>Redução de multicolinearidade das variáveis de precipitação</i>	43
4.3.5	<i>Simulação dos arranjos analíticos</i>	44
4.4	Especificação do Modelo GVAR	45
4.4.1	<i>Modelo VARX para cada empresa</i>	46
4.4.2	<i>Agregação e estabelecimento do sistema GVAR</i>	47
4.4.3	<i>Testes de estabilidade, seleção da ordem de defasagem e diagnóstico do modelo</i>	49
4.4.4	<i>Funções Impulso-Resposta e Decomposição da Variância do Erro de Previsão</i>	52
5	RESULTADOS E DISCUSSÃO	55
5.1	Cálculo, trajetória e propriedades empíricas do IboAgro (atendendo ao Objetivo Específico 1)	55
5.2	Impacto do fenômeno El Niño (ONI) sobre o desempenho agregado do agronegócio (IboAgro), com controles climáticos regionais (Atendendo ao Objetivo Específico 2)	59

5.2.1	<i>Resultados do Arranjo Analítico 1 (dinâmico com ONI e precipitação conforme região)</i>	59
5.3	Resposta a episódios ENSO, assimetrias e heterogeneidade regional, evidências de canal climático (Atendendo ao Objetivo Específico 3)	62
5.3.1	<i>Assimetria ENSO: ONI positivo (El Niño) versus ONI negativo (La Niña)</i>	62
5.3.2	<i>Canais climáticos e heterogeneidade regional: ONI versus precipitação por macrorregião</i>	62
5.4	Análise complementar: síntese do clima via PCA e desempenho do Arranjo Analítico 3	65
5.4.1	<i>Variância explicada e estrutura do PC1</i>	65
5.4.2	<i>Resultados do Arranjo Analítico 3 e implicações</i>	68
5.5	Síntese integrada dos Arranjos Analíticos e comparação de desempenho	70
6	CONSIDERAÇÕES FINAIS	72
	REFERÊNCIAS	71
	APÊNDICE A – SÉRIES HISTÓRICAS AGREGADAS	75
	APÊNDICE B – SCRIP EM RStudio	77

1 INTRODUÇÃO

As variações climáticas globais, intensificadas nas últimas décadas, provocam impactos significativos sobre os sistemas produtivos, especialmente o agronegócio, setor altamente sensível a essas instabilidades (IPCC, 2022). Entre os eventos climáticos de maior influência, destaca-se o fenômeno El Niño, caracterizado pelo aquecimento anormal das águas do Oceano Pacífico Equatorial, o que desencadeia alterações nos padrões de precipitações e de temperaturas em diversas regiões do globo (McPhaden; Santoso; Cai, 2020).

Os efeitos do El Niño não se limitam ao Território Brasileiro. Em escala global, o fenômeno é associado a secas severas na Austrália e no Sudeste Asiático, enchentes em regiões da América do Sul e nos Estados Unidos, bem como ao crescimento de incêndios florestais na Indonésia e à redução da pesca na costa do Peru, em decorrência da diminuição do suprimento de nutrientes nas águas superficiais (Trenberth, *et al.*, 1997; Salisu *et al.*, 2022). Estudos internacionais demonstram que a ocorrência do El Niño é passível de provocar impactos inflacionários ao elevar os preços de *commodities* agrícolas e energéticas, afetando cadeias globais de suprimentos, consumo e produção (Salisu *et al.*, 2022; Marpaung *et al.*, 2019). Ademais, há evidências de que as suas repercussões são suscetíveis de atingir os mercados financeiros e desencadear crises alimentares em países dependentes de importações de grãos (Pierre; Gutierrez, 2020; Ahmadi *et al.*, 2022).

A natureza transnacional dos impactos do El Niño torna evidente a necessidade de abordagens analíticas que considerem a complexidade das interconexões econômicas e climáticas. Conforme salientam Ubilava (2016) e Ahmadi *et al.* (2022), as anomalias associadas ao fenômeno estão propícias a afetar a oferta e os preços dos produtos agropecuários, bem como desencadear efeitos colaterais sobre os mercados financeiros, a inflação global e a segurança alimentar. Por exemplo, as quebras de safra em países exportadores, como Austrália e Indonésia, contribuem para a elevação dos preços internacionais de grãos, o que impacta diretamente o custo dos insumos do agronegócio em países importadores, incluindo o Brasil. Simultaneamente, a valorização de ativos considerados “porto seguro”, como o ouro e a prata, é intensificável durante episódios de El Niño, refletindo o aumento da percepção de risco econômico sistêmico (Salisu *et al.*, 2022).

Demais disso, os efeitos do El Niño assumem caráter assimétrico e persistente. A literatura especializada aponta que regiões geográficas distintas reagem de maneiras diversas à intensificação do fenômeno, tanto em termos de variabilidade climática quanto de repercussões econômicas (Dufrenot, 2023; Floride *et al.*, 2025). Enquanto na América do Sul ocorrem

padrões de precipitação acima da média, partes da África, Sudeste Asiático e Oceania enfrentam secas extremas, impactando cadeias produtivas globais de alimentos, fibras e energia. Nesse sentido, analisar os efeitos do El Niño no agronegócio brasileiro em decorrência de tais episódios exige a consideração de variáveis domésticas e a incorporação de choques globais, capazes de alterar os fundamentos de mercado e o desempenho das exportações brasileiras, dado o seu crescente grau de inserção nos mercados internacionais.

No Brasil, as manifestações do El Niño impactam diretamente a produção agropecuária, influenciando as produtividades de ordem vegetal e da pecuária e, conseqüentemente, os resultados das empresas agroindustriais (Assad *et al.*, 2022). Eventos como estiagens prolongadas no Nordeste e excesso de chuvas no Sul comprometem o abastecimento de matéria-prima para a indústria, alteram custos de produção, de logística e afetam os preços de comercialização (Lima; Zilli; Cunha, 2023). Tais impactos reforçam a interdependência de fatores climáticos e variáveis econômicas, exigindo análises que integrem riscos ambientais à performance financeira das organizações.

Em expressas circunstâncias, emerge a necessidade de compreender de que maneira o El Niño influencia os resultados das empresas do agronegócio brasileiro. Tal investigação é relevante tanto para subsidiar estratégias da gestão de risco e adaptação climática como a fim de contribuir com políticas públicas direcionadas à sustentabilidade e à estabilidade ante choques do agronegócio nacional (Torres *et al.*, 2021).

2 OBJETIVOS

O objetivo geral deste estudo consiste em analisar os efeitos do fenômeno El Niño sobre o agronegócio brasileiro, considerando o período de 1968 a 2024. Especificamente, o estudo intenta

- (i) criar um índice representativo do agronegócio brasileiro (a ser denominado IboAgro), com base na metodologia utilizada para o cálculo do Ibovespa, considerando exclusivamente as empresas do setor do agronegócio listadas na bolsa de valores brasileira;
- (ii) estimar o impacto do fenômeno El Niño sobre o desempenho econômico-financeiro do agronegócio brasileiro, utilizando o índice IboAgro como indicador sintético estabelecido para captar a dinâmica agregada da performance setorial, funcionando como *proxy* da rentabilidade e do desempenho econômico do setor; e
- (iii) investigar a resposta do setor do agronegócio a episódios do El Niño, por meio da variação do Índice IboAgro, bem como analisar os impactos regionais associados ao fenômeno, com vistas a identificar padrões diferenciados de sensibilidade climática entre as distintas regiões brasileiras.

O objetivo do cálculo do IboAgro é estabelecer um indicador sintético que reflita de modo mais fidedigno o comportamento econômico-financeiro das principais companhias do agronegócio com elevado volume de negociação na B3 (Brasil, Bolsa, Balcão). Foi elaborado com critérios consistentes de inclusão e permanência, corrigindo as distorções observadas em razão das entradas e saídas de empresas do agronegócio na/da composição tradicional do índice Ibovespa. Com isso, intentou-se obter uma métrica estável e específica, apta a captar as variações reais do setor à extensão do tempo, especialmente em resposta a choques climáticos como os provocados pelo fenômeno El Niño.

A pesquisa delimita-se à análise das principais empresas do agronegócio brasileiro, dos setores agrícola, pecuário e agroindustrial, com dados financeiros divulgados publicamente, abrangendo indústrias de grãos, carnes e derivados, laticínios e biocombustíveis. A metodologia adota um enfoque quantitativo, utilizando modelos econométricos para estimar o efeito do El Niño sobre as variáveis financeiras selecionadas, com base em indicadores climáticos oficiais fornecidos por instituições como o Instituto Nacional de Meteorologia (Inmet) e a Administração Nacional Oceânica e Atmosférica (NOAA).

Espera-se que os resultados desta Dissertação contribuam para o aprofundamento do conhecimento sobre a interação do clima com o desempenho econômico das cadeias do agronegócio, fornecendo subsídios à formulação de ações para a redução dos riscos e à elaboração de estratégias empresariais mais adaptativas.

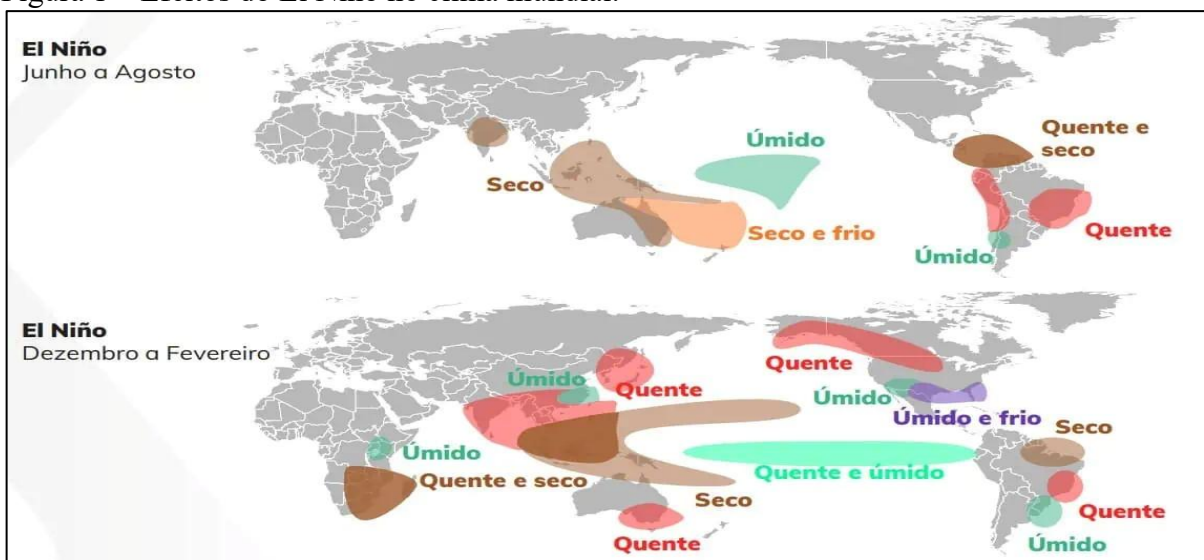
3 REVISÃO DE LITERATURA

A compreensão dos efeitos do fenômeno El Niño sobre o desempenho do agronegócio brasileiro exige, preliminarmente, uma análise sistemática da literatura que articula os fundamentos climatológicos do fenômeno às suas repercussões econômicas e produtivas. Nesse sentido, esta sessão apresenta uma revisão teórica e empírica acerca das principais abordagens que investigam a variabilidade climática associada ao sistema El Niño – Oscilação Sul (ENSO), seus impactos sobre a agricultura e a pecuária, bem como suas implicações para a rentabilidade das empresas do agronegócio. Adicionalmente, discute-se o papel dos indicadores financeiros, com destaque para o Índice Bovespa, na mensuração do desempenho setorial, estabelecendo as bases conceituais que sustentam a construção do índice IboAgro. Assim, a seção encontra-se estruturada de modo a contemplar, inicialmente, os aspectos físicos e climáticos do fenômeno, avançando para suas consequências econômicas e, por fim, abordando sua relação com o mercado financeiro e o comportamento das empresas do setor.

3.1 Fenômeno El Niño

A compreensão da sua origem é essencial para interpretar seus impactos globais, sobretudo em regiões tropicais e subtropicais fortemente dependentes da regularidade climática (Figura 1). O fenômeno é reconhecido como parte integrante do sistema de variabilidade natural da Terra, estabelecendo conexões entre oceano e atmosfera, que alteram, de maneira significativa, o comportamento climático em escala planetária.

Figura 1 – Efeitos do El Niño no clima mundial.



Fonte: StoneX.

Sua observação inicial não pertence à ciência moderna, pois surge das experiências cotidianas de pescadores da costa do Peru e do Equador, séculos antes de ser formalmente investigado. Os registros históricos indicam que pescadores peruanos notavam, em determinados anos, um aquecimento incomum das águas do Pacífico próximo à costa, particularmente durante o período natalino. Esse aquecimento fazia reduzir drasticamente a oferta de peixes, sobretudo da anchova, e alterava os padrões de ventos e marés. O fenômeno era tão marcante que recebeu o nome de El Niño, numa referência ao Menino Jesus, já que costumava ocorrer por volta de dezembro. Com o tempo, esses pescadores compreenderam que tais episódios afetavam toda a dinâmica pesqueira e traziam impactos econômicos significativos às comunidades costeiras (Cane, 2005).

Sob a perspectiva científica contemporânea, o fenômeno El Niño é caracterizado pelo aquecimento anômalo das águas superficiais do Oceano Pacífico Equatorial, região que abriga um complexo sistema de interação do oceano com a atmosfera. Nessa faixa tropical, sobra estabelecida uma dinâmica física marcada pela atuação dos ventos alísios, correntes oceânicas e gradientes térmicos que, em condições normais, garantem a manutenção do equilíbrio climático regional e global.


Em anos considerados normais, os ventos alísios sopram predominantemente de leste para oeste ao largo da faixa equatorial, deslocando as águas superficiais mais quentes em direção ao Pacífico Ocidental, especialmente nas proximidades da Indonésia e da Austrália. Esse deslocamento promove o acúmulo de água quente nessa porção do oceano, elevando a convecção atmosférica e favorecendo a formação de chuvas intensas na região. Simultaneamente, na costa oeste da América do Sul, particularmente no Peru e no Equador, ocorre o afloramento de águas mais frias e ricas em nutrientes provenientes das camadas mais profundas do oceano, processo conhecido como ressurgência. Esse mecanismo contribui para a regulação térmica do Pacífico Equatorial e sustenta importantes atividades econômicas, como a pesca.

Esse arranjo configura um sistema de circulação acoplado oceano-atmosfera, responsável por influenciar diretamente os regimes de precipitação, a circulação atmosférica tropical e, por consequência, padrões climáticos em diversas regiões da Terra. Quando, entretanto, ocorre o fenômeno El Niño, essa dinâmica é objeto de alterações significativas. O enfraquecimento dos ventos alísios reduz o transporte das águas quentes para o Pacífico Ocidental, ensejando que essas águas se desloquem em direção à porção central e oriental do oceano. Como resultado, há diminuição da ressurgência na costa sul-americana, aumento da

temperatura superficial do mar nessa área e reorganização dos sistemas de circulação atmosférica.

A Figura 2 ilustra comparativamente o funcionamento da circulação oceânica e atmosférica no Pacífico Equatorial em condições normais e durante episódios de El Niño. Observam-se, na representação gráfica, o enfraquecimento dos ventos alísios, a redistribuição das massas de água quente e a alteração nos padrões de formação de nuvens e precipitação. Essa mudança estrutural na dinâmica climática evidencia o modo como pequenas variações nos mecanismos físicos do Pacífico são suscetíveis de desencadear impactos de grande magnitude sobre os sistemas produtivos, especialmente aqueles intensivamente dependentes das condições climáticas, como o agronegócio.

Figura 2 – Funcionamento da circulação atmosférica e oceânica no Pacífico Equatorial em anos normais e durante o fenômeno El Niño.



Fonte: Adaptado de NOAA (*Nacional Oceanic and Atmospheric Administration*).

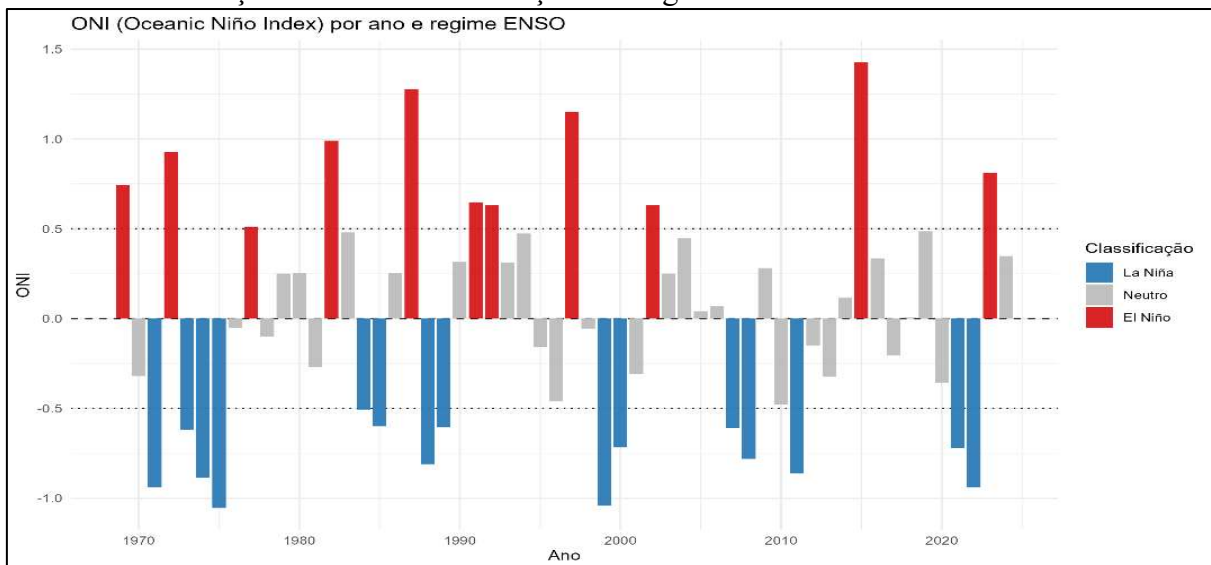
Durante a formação do El Niño, esses ventos alísios enfraquecem ou até mesmo invertem sua direção. O enfraquecimento concede oportunidade a que a massa de água quente se desloque para o Pacífico Central e Oriental, alterando o gradiente de temperatura e desencadeando uma reorganização da circulação atmosférica. Essas mudanças perturbam o padrão conhecido como Oscilação Sul, configurando o sistema El Niño-Oscilação Sul (ENSO), um dos principais motores da variabilidade climática global (IPCC, 2022).

O aquecimento anômalo das águas superficiais modifica a convecção atmosférica e altera a distribuição das chuvas nos trópicos, produzindo secas prolongadas em algumas regiões e precipitações excessivas em outras. Essa redistribuição da energia térmica afeta o hemisfério ocidental e repercute em cadeias produtivas e ecossistemas em todo o mundo. Segundo Cane (2005), constitui um dos fenômenos mais estudados da climatologia moderna, justamente por suas consequências econômicas e sociais de grande alcance.

É importante ressaltar que o El Niño não é um evento isolado, mas parte de um ciclo natural que altera fases quentes (El Niño), frias (La Niña) e neutras. A duração e a

intensidade variam de acordo com fatores complexos, ainda objeto de pesquisa científica. Apesar de ser um fenômeno natural, mudanças estruturais observadas no clima global constantemente suscitam debates sobre a possibilidade de intensificação desses eventos nas próximas décadas, conforme alertado por estudos recentes do IPCC (2022). O Gráfico 1 ilustra a evolução anual do *Oceanic Niño Index* (ONI), bem como a classificação dos regimes climáticos associados ao fenômeno ENSO no decurso do período analisado.

Gráfico 1 – Evolução do ONI e classificação dos regimes ENSO.



Fonte: NOAA (*Nacional Oceanic and Atmospheric Administration*); elaborado pelo autor.

Observa-se alternância recorrente entre episódios de El Niño, La Niña e neutralidade climática, com intensidades distintas à medida temporal. Essa variabilidade reforça o papel do ENSO como um dos principais mecanismos de transmissão de choques climáticos com potencial impacto sobre a atividade agropecuária.

O fenômeno El Niño reflete uma dinâmica climática que vai além da simples elevação da temperatura oceânica. Conforma um processo sistêmico, no qual pequenas alterações físicas geram efeitos globais que se multiplicam em distintas escalas, afetando a economia, a agricultura, os recursos hídricos e a segurança alimentar em países com fortes vínculos ao setor primário. A compreensão desse fenômeno é indispensável para o desenvolvimento de estratégias eficientes de adaptação, capazes de reduzir vulnerabilidades e orientar políticas públicas baseadas em evidências científicas.

3.1.1 El Niño e seus Impactos Climáticos

O fenômeno El Niño é amplamente reconhecido como uma das principais manifestações de variabilidade climática de origem natural, caracterizando-se pelo

aquecimento anormal das águas superficiais do Oceano Pacífico Equatorial. Essa anomalia térmica desencadeia alterações profundas nos padrões de precipitação, temperatura e circulação atmosférica em diversas regiões do globo.

Segundo Mota *et al.* (2020), as manifestações do El Niño resultam tanto em secas severas quanto em chuvas excessivas, dependendo da região afetada. Para o Brasil, tais eventos têm implicações diretas na agricultura e na pecuária, alterando a produtividade e impactando a sustentabilidade econômica de setores sensíveis ao clima.

Durante os episódios de El Niño, as regiões Norte e Nordeste do Brasil, frequentemente, enfrentam reduções acentuadas nas chuvas, levando a estiagens prolongadas que afetam a disponibilidade hídrica e comprometem o rendimento das culturas agrícolas. Por outro lado, o Sul do País tende a registrar um aumento das precipitações, o que é capaz de beneficiar algumas culturas, mas também provocar alagamentos e prejuízos a infraestrutura produtiva (Pereira; Dohler Junior, 2024). O IPCC (2007) evidencia que esses eventos devem se intensificar nas próximas décadas, tanto em frequência quanto em magnitude, o que representa uma ameaça crescente à estabilidade dos sistemas produtivos.

Na contextura internacional, o El Niño provoca efeitos significativos, o que é historicamente associado a episódios extremos como fome em massa, colapsos agrícolas e crises sociais. Grove e Chappell (2000) e Davis (2001) documentam que eventos ocorridos de 1876 a 1902 contribuíram para a morte de milhões de pessoas em países como Índia, China e Brasil.

De acordo com Salisu *et al.* (2022), as perturbações climáticas causadas pelo El Niño elevam os preços globais de *commodities* agrícolas e energéticas, gerando pressões inflacionárias em mercados emergentes e desenvolvidos. Esses choques climáticos repercutem diretamente nos mercados financeiros, aumentando a volatilidade e estimulando a demanda por ativos considerados “portos seguros”.

Um dos efeitos colaterais observados é a valorização de metais preciosos, como ouro e prata, em resposta ao crescimento da percepção de risco sistêmico decorrente desses eventos climáticos extremos. Esses ativos atuam como instrumentos de proteção durante períodos de instabilidade (Salisu *et al.* 2022).

Ahmadi *et al.* (2022) sugerem que os impactos econômicos do El Niño devem ser incorporados a projeções macroeconômicas e aos modelos de avaliação de riscos, dada a sua capacidade de afetar receitas externas, o câmbio e decisões de política monetária em países exportadores de *commodities*.

Os impactos do fenômeno também afetam a segurança alimentar global. Segundo Bastianis *et al.* (2018), a queda na produção de alimentos decorrente das variações climáticas acentua desigualdades sociais e eleva os preços, ampliando a vulnerabilidade de populações de baixa renda. Em países do Sudeste Asiático e da África, onde predomina a agricultura de subsistência, os efeitos do El Niño são particularmente graves. Marpaung *et al.* (2019) relatam que secas severas associadas ao fenômeno comprometem colheitas, provocam insegurança alimentar e agravam crises humanitárias.

Dufrenot (2023) acentua que as mudanças nos padrões de evapotranspiração e nos regimes de chuvas impactam diretamente o abastecimento de água e os ciclos de cultivo em regiões tropicais, o que representa risco à sustentabilidade operacional dos sistemas produtivos.

Os efeitos do El Niño não ocorrem uniformemente. A literatura especializada ressalta sua natureza assimétrica: enquanto determinadas áreas enfrentam secas, outras registram inundações e erosão, com perdas de produtividade e danos às estruturas rurais (Floride *et al.* 2025).

Além dos efeitos físicos, o El Niño afeta o comércio internacional e os fluxos logísticos. Ubilava (2018) aponta que tais eventos são capazes de interromper cadeias de suprimento, elevar os custos de transporte e aumentar a volatilidade nos preços de produtos agrícolas.

Os impactos do El Niño, muitas vezes, ultrapassam o período em que o evento ocorre, prolongando-se por trimestres subsequentes. Tais efeitos persistentes influenciam investimentos, decisões estratégicas e políticas públicas (Ubilava; Holt, 1968).

A imprevisibilidade do clima força os produtores brasileiros a adotarem tecnológicas mais adaptativas. Assad *et al.* (2020) destacam o uso crescente de sistemas de irrigação, sementes tolerantes à seca e técnicas de manejo conservacionista como modalidades de adaptação.

Bento *et al.* (2020) defendem o uso de modelos de previsão climática como instrumentos-chave para antecipar impactos e planejar saídas estratégicas em contextos de elevada variabilidade meteorológica.

A construção de infraestruturas com maior capacidade de enfrentamento, como silos elevados, drenagem adequada e barragens de contenção, também é recomendada como parte das ações de adaptação ao novo regime climático (Torres *et al.* 2021).

Segundo Pierre e Gutierrez (2020), o acesso a crédito direcionado e a informações climáticas qualificadas são determinantes para que os produtores tomem decisões assertivas e minimizem perdas.

A articulação entre conhecimento científico, planejamento territorial e gestão de risco é central para transformar o desafio climático em oportunidade de inovação, especialmente no contexto do agronegócio tropical (Dufrenot, 2023).

Políticas públicas de enfrentamento aos riscos climáticos devem se fundamentar em evidências científicas e promover ações coordenadas de prevenção, adaptação e controle de impactos, envolvendo agentes públicos e privados de maneira integrada.

3.1.2 Efeitos do El Niño na Agricultura Brasileira

A agricultura brasileira, reconhecida mundialmente por sua relevância econômica e pelo volume de exportações, é particularmente vulnerável aos impactos do El Niño, dadas as suas características dependentes do clima.

Diversas culturas agrícolas oferecem respostas diferenciadas às alterações climáticas, como observado nos estudos de Dalmago *et al.* (2018), que investigaram os efeitos do El Niño sobre a cultura da canola no Brasil. Os resultados indicaram que, em anos de El Niño, o rendimento de grãos de canola tende a ser negativamente afetado, com reduções significativas da produtividade.

Nos anos em que o El Niño é intenso, o rendimento de grãos de várias culturas é comprometido, evidenciando a relação negativa entre a variabilidade climática e o desempenho agrícola. A cultura da soja, que ocupa posição de destaque no agronegócio brasileiro, também é impactada, embora os efeitos variem conforme a localização geográfica e a fase do ciclo da cultura.

Para a soja no Sul do Brasil, Bento *et al.* (2020) demonstraram que o El Niño é passível de, paradoxalmente, trazer efeitos positivos sobre a produção, em decorrência da maior disponibilidade hídrica durante o período crítico de desenvolvimento da planta. Esse benefício, entretanto, é contrabalançável por problemas logísticos decorrentes do excesso de chuvas. Essas mesmas condições climáticas, contudo, resultam em perdas severas em outras regiões, como o Centro-Oeste, onde o excesso de precipitação dificulta as operações de colheita, aumenta a incidência de doenças e compromete a qualidade do produto colhido.

A variabilidade climática associada ao El Niño é capaz de induzir ao surgimento de doenças fúngicas, como a ferrugem asiática da soja, prejudicando diretamente o volume e a qualidade da produção e elevando os custos com defensivos agrícolas.

As culturas de inverno, como trigo e aveia, também são sensíveis ao excesso de umidade. Durante a fase de enchimento de grãos, muitas vezes, volumes elevados de precipitação comprometem o desenvolvimento fisiológico das plantas, favorecem a incidência

de doenças fúngicas, dificultam operações de manejo e colheita e, conseqüentemente, reduzem tanto a produtividade quanto a qualidade final dos grãos, ensejando impactos relevantes sobre o abastecimento interno e a competitividade das exportações. De maneira paralela, o excesso de chuvas também prejudica a pecuária, uma vez que a elevada umidade favorece a proliferação de agentes patogênicos, aumenta a incidência de doenças nos rebanhos, compromete o bem-estar animal e provoca a degradação ou encharcamento das pastagens, reduzindo a disponibilidade e a qualidade da alimentação. Esse conjunto de efeitos evidencia que eventos climáticos caracterizados por precipitações intensas produzem repercussões sistêmicas sobre distintos segmentos do agronegócio, ampliando a vulnerabilidade produtiva e econômica do setor.

No Nordeste brasileiro, a redução drástica das chuvas ocasionada pelo El Niño compromete o cultivo de lavouras de subsistência e a agricultura familiar, agravando as condições de insegurança alimentar e aumentando a vulnerabilidade social em uma região já fragilizada economicamente.

Estudos de Schaab e Reginato (2018) mostram que o impacto do El Niño na agricultura não se limita à produção física, afetando também a estabilidade dos preços agrícolas no mercado interno, com efeitos inflacionários em produtos básicos. Assim, o conhecimento dos padrões históricos de resposta das culturas às variações do El Niño é fundamental para o planejamento das atividades agrícolas e definição de estratégias da gestão de risco adequadas.

Empresas e produtores rurais que conseguem incorporar informações climáticas em seus sistemas de decisão denotam maior capacidade de resiliência perante as incertezas climáticas, assegurando a continuidade da produção e a manutenção de sua competitividade.

Portanto, os efeitos do El Niño sobre a agricultura brasileira devem ser analisados de maneira sistêmica e multidimensional, considerando tanto as implicações produtivas quanto as repercussões econômicas e sociais.

A adaptação do sistema produtivo a essas condições climáticas adversas exige investimentos em pesquisa, inovação tecnológica, políticas de apoio à agricultura de risco climático e fortalecimento das redes de proteção social nas áreas mais vulneráveis.

3.1.3 Impactos do El Niño na Rentabilidade das Empresas do Agronegócio

O agronegócio caracteriza-se como um sistema produtivo complexo, integrado e interdependente, que abrange desde a produção agropecuária até a agroindústria, os serviços logísticos, financeiros e tecnológicos associados às cadeias produtivas. Conforme apontam Torres *et al.* (2021), o agronegócio deve ser compreendido como um conjunto articulado de

atividades que envolve insumos, produção primária, processamento industrial e distribuição, constituindo um ambiente econômico altamente sensível às variações climáticas e estruturado em redes de oferta e demanda retroalimentadas. Nessa mesma perspectiva, Assad *et al.* (2022) ressaltam que o setor opera sob intensiva dependência das condições meteorológicas e ambientais, dado que sua performance econômico-produtiva resulta da interação de múltiplos elos, cuja eficiência depende da disponibilidade hídrica, estabilidade climática e da regularidade dos ciclos agrícolas. Essa concepção sistêmica reforça a ideia de que qualquer perturbação climática significativa, como o El Niño, afeta a produção primária e toda a dinâmica financeira e operacional das empresas agroindustriais.

As organizações do agronegócio brasileiro, ao dependerem diretamente do desempenho da agricultura e da pecuária, estão expostas aos riscos inerentes às variações climáticas. O fenômeno El Niño, em particular, destaca-se por sua capacidade de desorganizar os ciclos produtivos, gerar incertezas nos mercados e comprometer a rentabilidade empresarial.

Conforme apontado pelo Cepea/CNA (2024), o Produto Interno Bruto (PIB) do agronegócio brasileiro registrou uma queda de 2,99% no ano de 2023, atribuída em grande medida às variações climáticas que afetaram a produção e os preços das *commodities* agropecuárias.

As perdas de produtividade agrícola, resultantes de estiagens prolongadas no Centro-Oeste e Nordeste, ou de excesso de chuvas no Sul, impactam diretamente a disponibilidade de matéria-prima para a indústria agroalimentar. Isso repercute na elevação dos custos logísticos, no aumento da ociosidade industrial e na redução da margem operacional das empresas processadoras.

A agroindústria nacional, especialmente nos segmentos de grãos e proteínas, é particularmente vulnerável aos efeitos do El Niño. Em anos de forte intensidade do fenômeno, culturas como soja e milho enfrentam perdas relevantes, o que encarece a produção de ração e, por consequência, eleva os custos para os setores de avicultura e suinocultura.

De acordo com Schaab e Reginato (2018), as anomalias climáticas introduzidas pelo El Niño criam ‘choques’ nos fluxos de suprimento e demanda, interrompendo cadeias produtivas e desorganizando estoques, fretes e prazos de entrega. Isso se traduz em maior volatilidade operacional e incerteza no planejamento financeiro das empresas.

Além dos efeitos diretos sobre a produção, o El Niño também interfere nos mercados globais de *commodities*. A depender da intensidade do fenômeno e de suas repercussões em países concorrentes do Brasil, como Estados Unidos e Argentina, há impactos nos preços internacionais e nas condições de competitividade externa.

Outro fator que influencia a rentabilidade é a volatilidade dos custos de produção, que tendem a se elevar em períodos de crise climática. O aumento nos preços de fertilizantes, defensivos agrícolas, sementes e combustíveis pressiona os custos variáveis e reduz a competitividade das empresas, especialmente as que operam com menor escala.

Essas pressões financeiras obrigam as empresas do agronegócio a revisar suas estratégias de produção e comercialização. A adoção de medidas de contenção de custos, de aumento da eficiência energética e de renegociação de contratos torna-se parte da rotina empresarial ante uma circunstância climática instável.

Ahmadi *et al.* (2022) evidenciam que o risco climático deve ser incorporado às análises financeiras e aos modelos de avaliação de ativos das empresas do setor primário. Ignorar tais variáveis é passível de resultar em subestimação dos riscos e em decisões econômicas ineficientes.

As companhias que integram cadeias globais de valor enfrentam desafios adicionais, como o encarecimento de seguros agrícolas, a escassez de fretes e a exigência de padrões ambientais mais rígidos por parte de importadores. Nessa contextura, a performance climática torna-se também um critério de competitividade.

A gestão de risco climático emerge como competência estratégica indispensável. Meios como seguro agrícola, contratos futuros, *hedge* cambial e diversificação territorial da produção são instrumentos utilizados para reduzir a exposição aos eventos extremos provocados pelo El Niño.

Ubilava (2016) e Dufrenot (2023) argumentam que empresas com melhor capacidade adaptativa demonstram maior robustez perante os choques ambientais. Investimentos em tecnologias de previsão meteorológica, sensoriamento remoto e manejo inteligente do solo são fundamentais para amortecer os impactos climáticos sobre a rentabilidade.

Empresas de médio e grande porte tendem a exibir maior capacidade de resposta, dado o acesso a linhas de crédito, à assistência técnica e à infraestrutura de armazenagem e escoamento. Em contrapartida, pequenos produtores inseridos em cadeias integradas são frequentemente os mais vulneráveis às perdas.

Haja vista o exposto, afirma-se que a rentabilidade das empresas do agronegócio brasileiro, em contextos marcados pela ocorrência do El Niño, dependerá da sua capacidade de antecipação, adaptação e resposta frente às alterações climáticas. A vulnerabilidade não é homogênea, mas é gerenciável com inteligência estratégica, investimento em inovação e acesso à informação qualificada.

3.1.4 Transmissão de Impactos Climáticos

Os efeitos do fenômeno El Niño sobre o agronegócio não se restringem apenas à produção agrícola e à rentabilidade das empresas diretamente envolvidas no setor. Eles se propagam em cadeia para diversos outros segmentos da economia brasileira, evidenciando a profunda interdependência das atividades produtivas.

A análise de insumo-produto realizada por Schaab e Reginato (2018) demonstrou que um choque climático na agricultura repercute em múltiplos setores econômicos. Isso ocorre por meio de efeitos diretos, indiretos e induzidos, alterando os fluxos de bens e serviços em escala nacional.

No primeiro nível de transmissão, destaca-se o impacto sobre a indústria de transformação. Setores como alimentos e bebidas, biocombustíveis, papel e celulose, têxteis e indústrias químicas agrícolas são diretamente afetados pela escassez ou elevação dos preços das matérias-primas.

Quando a produção agrícola é comprometida, a capacidade operacional dessas indústrias é reduzida. Com isso, há aumento nos custos de produção, pressões inflacionárias e redução na oferta de produtos ao consumidor final.

No setor de energia, o El Niño é propício a alterar significativamente o regime hidrológico, principalmente em bacias localizadas nas regiões Norte e Centro-Oeste. Isso afeta a geração de energia hidrelétrica e obriga a ativação de termelétricas, com custos superiores e maior impacto ambiental (Dufrenot, 2023). Essa substituição de matriz energética encarece o custo da eletricidade para consumidores industriais e residenciais, afetando a competitividade de setores que dependem intensamente de energia elétrica, como siderurgia, mineração e agroindústria.

O setor de transporte e logística também é contrafeito com os resultados do El Niño. Chuvas intensas quase sempre danificam a infraestrutura rodoviária e ferroviária, provocam o fechamento de portos e atrasam o escoamento da produção. Isso encarece fretes, causa perdas pós-colheita e aumenta o risco de desabastecimento em centros urbanos. Floride *et al.*, (2025) alertam para a noção de que essas interrupções logísticas provocam gargalos que afetam toda a cadeia produtiva, incluindo o comércio varejista e atacadista, gerando impactos sistêmicos sobre o consumo e a arrecadação fiscal.

O setor financeiro, por sua vez, responde negativamente à elevação da inadimplência nos contratos de crédito rural empresarial. A menor renda gerada pela atividade

agropecuária reduz a capacidade de pagamento, elevando os riscos de crédito e exigindo maior provisionamento por parte das instituições financeiras (Ahmadi *et al.*, 2022).

As seguradoras também enfrentam pressões adicionais, em especial no segmento de seguro agrícola. A ocorrência de eventos extremos conduz ao crescimento das indenizações e é capaz de comprometer a sustentabilidade dos produtos financeiros dirigidos ao setor primário.

A retração da atividade agroindustrial impacta o mercado de trabalho formal e informal. Trabalhadores temporários, safristas e empregados da indústria de base agropecuária são frequentemente os primeiros a perder seus postos em períodos de retração climática prolongada.

Essa perda de renda, por sua vez, estorvam o comércio local, os serviços pessoais e a arrecadação de tributos municipais. A redução da atividade econômica em regiões lesadas gera um ciclo de empobrecimento e eleva a demanda por políticas públicas emergenciais.

Do ponto de vista da segurança alimentar, a diminuição da oferta de alimentos básicos e hortifrutigranjeiros é passível de elevar o Índice Nacional de Preços ao Consumidor Amplo (IPCA), pressionando a inflação e prejudicando especialmente as famílias de baixa renda (Pierre e Gutierrez, 2020).

A redução do consumo desses alimentos também mexe com setores como o de embalagens, comércio atacadista, feiras livres e supermercados, reforçando os efeitos em cadeia do El Niño sobre os demais setores produtivos.

As empresas fornecedoras de insumos agrícolas, como fertilizantes, sementes e máquinas, registram queda nas vendas durante períodos de crise no agronegócio. Esse movimento retrai investimentos no setor e reduz a inovação tecnológica no campo.

Além dos impactos econômicos, os efeitos climáticos extremos aumentam a demanda por serviços públicos essenciais. Municípios prejudicados por enchentes ou estiagens enfrentam maior pressão sobre os sistemas de saúde, educação e defesa civil, comprometendo os orçamentos públicos e exigindo apoio estadual e federal (Marpaung *et al.*, 2019).

Esses efeitos mostram como o El Niño atua como um risco sistêmico, multiplicando seus impactos em uma economia intensiva dependente do setor primário e de infraestrutura vulnerável às mudanças climáticas. A compreensão da complexidade dessa transmissão intersetorial é essencial para a formulação de políticas públicas e particulares mais eficazes. Planejamento integrado, fortalecimento institucional e cooperação multissetorial são forças para enfrentar os desafios impostos por eventos climáticos extremos.

Dessa maneira, analisar os efeitos do El Niño sob uma perspectiva intersetorial enseja entender que a resiliência da economia brasileira está intimamente ligada à capacidade do agronegócio de se adaptar às mudanças climáticas e de proteger os setores que dele dependem direta ou indiretamente.

3.1.5 Considerações sobre a Resiliência e Adaptação das Empresas do Agronegócio

Haja vista a intensificação dos eventos climáticos extremos, como o El Niño, a formulação da resiliência e a adoção de estratégias de adaptação pelas empresas do agronegócio tornam-se componentes essenciais para a sustentabilidade e a competitividade do setor. A resiliência, nesse contexto, é entendida como a capacidade das empresas de resistir, absorver, responder e se recuperar ante choques climáticos recorrentes (IPCC, 2022).

Segundo Lemos (2020), o conceito de resiliência está associado à capacidade que pessoas, famílias, comunidades ou sistemas produtivos possuem de antecipar, absorver, adaptar-se e recuperar-se diante de choques adversos, como eventos climáticos extremos, crises econômicas ou instabilidades estruturais. Nessa perspectiva, a resiliência não se limita à simples resistência ao impacto, mas envolve a habilidade de reorganizar e restabelecer as funções essenciais do sistema prejudicado, reduzindo sua vulnerabilidade e ampliando sua capacidade adaptativa à medida do tempo. Constitui, portanto, um atributo dinâmico, relacionado à superação de perturbações e à manutenção do funcionamento socioeconômico mesmo em contextos de adversidade.

Empresas que operam com margens estreitas ou que estão excessivamente expostas ao cultivo de monoculturas de alto risco climático tendem a ser mais vulneráveis aos impactos negativos do El Niño. De outra parte, aquelas que investem em inovação tecnológica, gestão de risco e diversificação de mercado demonstram maior capacidade de resposta e recuperação (Ubilava, 2016).

Entre as estratégias de adaptação, destaca-se a diversificação geográfica da produção agrícola. Ao distribuir suas operações em variegadas regiões climáticas do País, as empresas diluem os riscos de perda simultânea, mantendo a continuidade do abastecimento mesmo diante de eventos localizados de seca ou excesso de chuvas.

Essa prática é muitas vezes complementada com o escalonamento de plantios, o uso de sementes com ciclos diferenciados e a rotação de culturas, medidas que ensejam maior flexibilidade operacional em face da imprevisibilidade climática (Floride *et al.*, 2025).

A adoção de tecnologias de monitoramento climático cresce nas últimas décadas. Com o avanço da inteligência artificial, sensores remotos e sistemas de georreferenciamento, é

possível acessar dados em tempo real sobre precipitação, temperatura, vento e umidade do solo. Esses indicativos são fundamentais para decisões estratégicas de plantio, colheita e logística (Ahmadi *et al.*, 2022).

Sistemas de alerta antecipado e modelagem preditiva também desempenham função crucial, dando azo a que empresas ajustem seu planejamento e alocação de recursos com base em previsões meteorológicas confiáveis (Marini, 2020).

Do ponto de vista da sustentabilidade produtiva, o uso de práticas como o plantio direto, a Integração Lavoura-Pecuária-Floresta (ILPF) e a irrigação inteligente contribuem para a adaptação climática e concorrem para a conservação de recursos naturais e o aumento da eficiência do uso da terra.

O acesso ao seguro rural é outro fator crítico para a adaptabilidade. Apesar da baixa penetração no Brasil, o seguro agrícola se mostra essencial para amortecer perdas em anos de eventos extremos. O desenvolvimento de seguros paramétricos, indexados a variáveis climáticas, tem ganhado destaque em regiões com maior frequência de perdas associadas ao El Niño (Salisu *et al.*, 2022).

Tais mecanismos oferecem liquidez rápida aos produtores, dando oportunidade à retomada das atividades e evitando o colapso financeiro de pequenas e médias empresas rurais. Ainda assim, é necessário ampliar a cobertura e a capacidade desses produtos em todo o Território Nacional.

A governança corporativa tem papel central, também, na gestão de riscos climáticos. Empresas que incorporam a variável em suas matrizes de risco e relatórios de sustentabilidade tendem a atrair mais investimentos, acessar crédito com melhores condições e melhorar sua imagem junto a *stakeholders* (Dufrenot, 2023).

A integração do risco climático às práticas contábeis e de auditoria tornou-se exigência em diversos mercados, especialmente no comércio internacional de *commodities*, onde critérios de rastreabilidade e de compromisso ambiental são cada vez mais valorizados.

A cooperação entre empresas, centros de pesquisa, universidades e agências de fomento também fortalece a capacidade adaptativa. Parcerias que promovem o desenvolvimento de tecnologias climáticas, como sementes resistentes e sistemas da gestão hídrica, são fundamentais para antecipar e mitigar os impactos do El Niño (Marpaung, 2019).

A elaboração da resiliência passa ainda por ações de governança territorial. Consórcios intermunicipais, redes regionais de assistência técnica e fóruns de articulação setorial atuam na implementação de planos de contingência, bancos de sementes, mapeamento de vulnerabilidade e capacitação de lideranças locais.

Nesse sentido, a adaptação ao El Niño não deve ser encarada como resposta emergencial e pontual, mas como parte estruturante de um novo modelo da gestão agro empresarial, que reconhece o risco climático como variável permanente do ambiente de negócios.

Essa abordagem exige planejamento de extenso prazo, avaliação contínua de realidades e investimentos em capacidades organizacionais que ensejem transformar vulnerabilidades em oportunidades de inovação e diferenciação competitiva (Gutierrez, Piras e Roggero, 2014).

Empresas que adotam comportamento proativo perante os desafios climáticos tendem a ser mais valorizadas por consumidores e investidores. A capacidade de adaptação torna-se, portanto, um ativo estratégico que reforça a competitividade e a sustentabilidade no extenso prazo.

3.2 O Índice Bovespa e a participação das empresas do agronegócio

O Índice Bovespa (Ibovespa) é reconhecido como o principal indicador de desempenho do mercado acionário brasileiro. Desenvolvido pela Brasil, Bolsa, Balcão (B3), o índice representa a variação média das cotações dos ativos com maior liquidez e mais relevância no mercado à vista da bolsa, funcionando como um termômetro da economia nacional.

A metodologia que sustenta o Ibovespa é rigorosa e visa a garantir representatividade e estabilidade. Conforme definido pela B3 (2025), este é um índice de retorno total, fato significativo de que, além da variação dos preços das ações, ele também incorpora os proventos distribuídos, como dividendos e juros sobre capital próprio. Essa abordagem intenta refletir com precisão o retorno efetivo dos investidores. O cálculo do Ibovespa é baseado em uma fórmula ponderada pela liquidez e pelo valor de mercado dos ativos que compõem sua carteira. A fórmula é assim expressa:

$$IBOV_t = \frac{\sum_{i=1}^n (P_{i,t} \cdot Q_{i,t})}{Divisor} \quad (1)$$

Nessa equação, $P_{i,t}$ representa o preço da ação da empresa i no tempo t , $Q_{i,t}$ é a quantidade de ações da empresa i em circulação, do índice, e o *Divisor* é um fator de ajuste que garante a continuidade histórica do índice mesmo após eventos como desdobramentos ou agrupamentos de ações (B3, 2024). No cálculo do Índice Bovespa, o divisor é um fator de ajuste utilizado para garantir que o índice mantenha sua continuidade à medida do tempo. Como o índice é calculado com suporte na soma do valor de mercado das ações que compõem sua

carteira teórica, mudanças na composição dessa carteira ou eventos corporativos, como desdobramentos, grupamentos ou substituição de empresas no índice, seriam habilitados a provocar variações artificiais no valor do indicador. Para evitar esse problema, o divisor é recalculado sempre que ocorre algum desses eventos, de modo que o nível do índice permaneça consistente antes e depois do ajuste. Em termos práticos, o divisor funciona com um elemento de normalização do índice, assegurando que sua variação reflita somente as mudanças efetivas nos preços das ações que compõem a carteira teórica.

A composição do índice é atualizada a cada quatro meses, nos primeiros dias úteis de janeiro, maio e setembro. A escolha das empresas baseia-se em critérios quantitativos como presença em pelo menos 95% dos pregões dos três últimos quadrimestres, participação mínima de 0,1% no volume financeiro negociado e classificado no Índice de Negociabilidade (IN)¹, que deve somar até 85% da liquidez acumulada.

Essa metodologia intenta assegurar que somente os papéis mais líquidos e representativos façam parte da carteira, excluindo ativos com baixa frequência de negociação, *penny stocks*², empresas em recuperação judicial ou em regime especial de administração.

No contexto do agronegócio, é importante evidenciar que o Ibovespa inclui, entre seus componentes, empresas altamente relevantes da cadeia produtiva agroindustrial. Na carteira de maio-agosto de 2024, destacam-se organizações que atuam em setores que vão da produção de grãos e carnes ao refino de biocombustíveis e papel celulose.

Quadro 1 – Empresas ligadas ao agronegócio de variados segmentos da cadeia produtiva da carteira do IBOVESPA (maio-agosto de 2024)

Empresa	Setor de atuação	Segmento do Agronegócio
JBS S.A.	Produção e processamento de carnes	Pecuária de corte
Marfrig	Alimentos processados	Pecuária de corte
BRF S.A.	Alimentos processados	Aves, suínos e grãos
Minerva Foods	Alimentos e exportação de carnes	Pecuária de corte
SLC Agrícola	Produção de grãos em larga escala	Agricultura de grãos
Raízen	Energia e biocombustíveis	Cana-de-açúcar, etanol
Suzano	Papel e celulose	Silvicultura
Klabin	Papel e embalagens	Silvicultura

Fonte: B3, 2024

Essas companhias inserem-se nos distintos elos do agronegócio, exercendo papéis estratégicos na geração de valor, emprego e arrecadação tributária. Empresas como JBS S.A.,

¹ Índice de Negociabilidade (IN) é um indicador utilizado para mensurar o grau de liquidez de um ativo no mercado, refletindo a frequência e o volume de negociações realizadas em determinado período.

² *Penny stocks* referem-se a ações de empresas de pequeno porte, geralmente negociadas a preços muito baixos por unidade, com reduzida liquidez e elevado grau de volatilidade.

maior processadora de carnes do mundo, possuem operação em cerca de 150 países, refletindo diretamente no volume de exportações do setor.

De acordo com o Ministério da Agricultura, Pecuária e Abastecimento (Mapa) (2023), os segmentos de carnes e grãos representaram cerca de 60% das exportações do agronegócio brasileiro em 2022. Isso evidencia a vigorosa correlação entre o desempenho dessas empresas e o comportamento macroeconômico do País.

A participação dessas organizações no Ibovespa revela sua importância no setor agropecuário e no mercado financeiro nacional. Seus resultados são monitorados por analistas, investidores e gestores de fundos, o que as torna especialmente sensíveis a eventos sistêmicos, como as variações climáticas extremas.

Eventos como o El Niño afetam diretamente os custos, a produção e as receitas dessas empresas, gerando impactos que, por sua vez, reverberam no próprio Ibovespa. Uma queda na produtividade agrícola, por exemplo, influi negativamente nos preços de insumos, diminui exportações e prejudica margens operacionais.

A volatilidade provocada por eventos climáticos também afeta o comportamento dos investidores. Ações de empresas com exposição ao risco climático tendem a exibir maior oscilação em períodos de incerteza, influenciando diretamente a performance do índice.

Demais disso, a metodologia do Ibovespa limita a participação de qualquer empresa a, no máximo, 20% do total do índice. Esse limite impede a concentração excessiva e assegura maior equilíbrio na composição setorial do índice.

Por outro lado, essa limitação oculta variações mais agudas em setores específicos, como o agropecuário, sobretudo em momentos de crise climática. Isso reforça a importância de se criar indicadores setoriais complementares, como o IboAgro, proposto neste estudo.

O IboAgro intenta isolar e acompanhar o desempenho das principais empresas do agronegócio que estão na bolsa, utilizando a mesma metodologia de cálculo do Ibovespa, mas corrigindo a descontinuidade causada pela rotatividade de empresas do índice geral.

Portanto, ao mesmo tempo em que o Ibovespa cumpre seu papel de indicador amplo do mercado acionário, ele também evidencia a relevância do setor do agronegócio para a economia nacional e sua vulnerabilidade a eventos como o El Niño. Compreender essa relação é essencial para análises financeiras, formulação de políticas públicas e decisões estratégicas.

4 METODOLOGIA

O conjunto de procedimentos metodológicos expressos nesta seção foi estruturado para atender ao objetivo geral da pesquisa, ensejando analisar, de maneira integrada e dinâmica, os efeitos do fenômeno El Niño sobre o desempenho do agronegócio brasileiro durante o período analisado.

4.1 Abordagem geral da pesquisa

Este estudo adota uma abordagem quantitativa, de natureza explicativa, com o objetivo de analisar os impactos climáticos associados ao fenômeno El Niño sobre o desempenho econômico das empresas do agronegócio brasileiro. A escolha metodológica fundamenta-se na necessidade de captar relações dinâmicas e intertemporais de variáveis climáticas e indicadores econômico-financeiros, reconhecendo que os efeitos do clima não se manifestam de modo instantâneo nem homogêneo no curso do tempo e do espaço.

O agronegócio caracteriza-se por ciclos produtivos extensos, elevada dependência de condições naturais e vigorosa integração com o mercado financeiro e de *commodities*. Nesse contexto, choques climáticos tendem a afetar a produção, os custos e a eficiência operacional de maneira defasada, o que justifica a utilização de modelos econométricos dinâmicos, capazes de incorporar persistência temporal e mecanismos de ajuste gradual, conforme recomendado na literatura econométrica clássica e aplicada (Gujarati; Porter, 2011; Wookdrige, 2021).

4.2 Delimitação temporal e amostral

Esta investigação perfilha como recorte temporal o período de 1968 a 2024, o qual abrange variados regimes climáticos e sucessivos episódios de fenômeno El Niño, de intensidades diversificadas. A escolha desse intervalo decorre, principalmente, da disponibilidade de séries históricas consistentes de dados climáticos e econômico-financeiros, bem como da necessidade de capturar efeitos de longo prazo associados às transformações estruturais do agronegócio brasileiro.

Do ponto de vista amostral, a análise considera um conjunto de 11 empresas do agronegócio brasileiro listadas na B3, que integraram a carteira do Ibovespa em distintos momentos do período analisado. Entre as companhias contempladas, encontram-se firmas com atuação em segmentos estratégicos da economia agroindustrial, tais como proteína animal, produção de grãos, papel e celulose, biocombustíveis e atividades florestais. Em termos de representatividade econômica, essas empresas respondem por parcela relevante da

capitalização do mercado acionário brasileiro, alcançando, em determinados períodos, aproximadamente 20% do peso total do Ibovespa, o que evidencia a importância do agronegócio na estrutura produtiva e financeira do País. Com efeito, a amostra selecionada enseja capturar de maneira consistente o desempenho corporativo do agronegócio brasileiro e sua interação com choques climáticos associados ao fenômeno El Niño.

Considerando as especificidades do agronegócio, especialmente a sazonalidade produtiva e a concentração de resultados no decurso do ano agrícola, optou-se por trabalhar com dados anuais. Essa escolha metodológica está alinhada à literatura que evidencia indicadores anuais como mais adequados para capturar o efeito líquido de choques climáticos sobre o desempenho econômico do setor, evitando distorções associadas a flutuações interanuais (Cai *et al.*, 2014).

4.3 Variáveis do estudo e indicadores de desempenho econômico

O Quadro 2 expressa a definição das variáveis utilizadas no estudo, incorporando tanto o índice IboAgro em nível, empregado na etapa de formulação do indicador, quanto à sua variação logarítmica anual, utilizada nas estimações econométricas subsequentes.

Quadro 2 – Variáveis do Modelo.

Variável	Indicador	Definição	Unidade	Fonte
Y ₁	IboAgro	Índice econômico-financeiro agregado que representa o desempenho médio das empresas do agronegócio.	adimensional	Elaboração própria, com dados de preços e capitalização de mercados das empresas obtidos na B3 e em bases financeiras como Economatica ou <i>Refinitiv</i> .
Y ₁ '	$\Delta \ln IboAgro$	Taxa de variação logarítmica anual do IboAgro, dada pela diferença dos logaritmos entre períodos, que aproxima o crescimento percentual e melhora a análise econométrica de retornos.	adimensional	
X ₁	Índice ONI (El Niño)	Índice de anomalia da temperatura da superfície do Oceano Pacífico Equatorial, utilizado para identificar a intensidade do fenômeno El Niño.	°C	NOAA – <i>National Oceanic and Atmospheric Administration, Climate Prediction Center</i> .
X ₂	Precipitação média – Centro-Oeste	Precipitação média anual da região Centro-Oeste do Brasil	mm	INTEM – Instituto Nacional de Meteorologia. Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP).
X ₃	Precipitação média – Nordeste	Precipitação média anual da região Nordeste do Brasil	mm	
X ₄	Precipitação média – Norte	Precipitação média anual da região Norte do Brasil	mm	
X ₅	Precipitação média – Sudeste	Precipitação média anual da região Sudeste do Brasil	mm	
X ₆	Precipitação média – Sul	Precipitação média anual da região Sul do Brasil	mm	

Fonte: elaborado pelo autor.

Com base nas fontes de dados descritas na seção imediatamente anterior, este experimento utiliza um conjunto de variáveis climáticas e econômico-financeiras para analisar os efeitos do fenômeno El Niño sobre o desempenho das empresas do agronegócio brasileiro. As variáveis independentes são compostas por indicadores climáticos de natureza global e regional. Especificamente, a intensidade do fenômeno climático global é captada pelo *Oceanic Niño Index* (ONI), enquanto suas manifestações espaciais no Território Nacional são representadas pelas médias anuais de precipitação nas grandes regiões brasileiras, Centro-Oeste, Nordeste, Norte, Sudeste e Sul.

Ressalta-se, contudo, que a distribuição espacial das precipitações no Território Brasileiro denota elevada heterogeneidade regional, refletindo as diferenças climáticas entre biomas e regiões produtivas. Assim, valores médios regionais são passíveis de ocultar variações locais relevantes na disponibilidade hídrica. Malgrado essa limitação, o uso de precipitação média agregada enseja captar tendências climáticas gerais associadas a eventos de grande escala, como o fenômeno El Niño, que afetam simultaneamente amplas áreas produtoras do País.

As variáveis dependentes são representadas pelo IboAgro e por sua taxa de variação logarítmica anual ($\Delta \ln IboAgro$). O IboAgro é utilizado na etapa de elaboração e caracterização do indicador setorial, uma vez que sintetiza o desempenho econômico-financeiro agregado das empresas do agronegócio listadas na B3, refletindo a dinâmica média do conjunto das firmas analisadas à proporção do tempo. Esse índice conduz a se identificar movimentos estruturais de expansão ou retração do setor, fornecendo uma visão agregada do seu comportamento econômico-financeiro.

Reconhecendo, no entanto, a natureza dinâmica dos choques climáticos, bem como as propriedades estatísticas típicas de séries financeiras agregadas, como persistência temporal, não estacionariedade e inexistência de tendências, as análises econométricas subsequentes utilizam como variável dependente principal não o índice em nível, mas a sua taxa de variação logarítmica anual ($\Delta \ln IboAgro$). Essa transformação enseja captar de maneira mais adequada os efeitos transitórios e dinâmicos dos choques climáticos associados ao fenômeno El Niño, além de reduzir problemas econométricos relacionados à autocorrelação e à interpretação espúria de relações de longo prazo.

Com efeito, a variável dependente associada ao desempenho agregado do agronegócio passa a ser definida como o retorno do IboAgro, expresso pela diferença do logaritmo natural do índice entre dois períodos consecutivos. Tal procedimento está em consonância com a literatura econométrica aplicada a mercados financeiros e à análise de choques macroeconômicos, que recomenda a modelagem em retornos quando o interesse recai

sobre variações intertemporais induzidas por eventos exógenos, como fenômenos climáticos extremos.

4.3.1 Justificativa para a exclusão das variáveis de temperatura regional

A decisão de retirar as variáveis de temperatura média regional das especificações econométricas adotadas neste estudo decorre de considerações tanto empíricas quanto metodológicas, relacionadas à coerência estatística do modelo e à adequada identificação dos efeitos climáticos sobre o desempenho do agronegócio brasileiro. Embora a temperatura seja reconhecida na literatura como um dos principais determinantes da produtividade agrícola, sua inclusão conjunta com variáveis de precipitação e com o índice ONI mostrou-se redundante e potencialmente problemática no contexto específico da modelagem proposta.

Do ponto de vista empírico, verificou-se que as variáveis de temperatura regional exibiam elevada correlação com o índice ONI, o qual já captura, de maneira sintética, anomalias climáticas globais associadas a alterações térmicas e hidrológicas. Essa sobreposição informacional tende a resultar numa multicolinearidade entre as variáveis independentes, comprometendo a precisão das estimativas e inflando os erros-padrão dos coeficientes associados à temperatura. Como consequência, a interpretação isolada dos efeitos térmicos tende a se tornar imprecisa e estatisticamente instável, dificultando a identificação clara dos canais de transmissão dos choques climáticos.

Em complemento, a inclusão simultânea das temperaturas regionais e das precipitações mostra-se metodologicamente questionável, uma vez que ambas refletem dimensões interdependentes do mesmo fenômeno climático. Em particular, no contexto do fenômeno El Niño, as variações de temperatura tendem a se manifestar juntamente com alterações no regime de chuvas, de modo que a introdução de ambas as variáveis no mesmo modelo é suscetível de levar à dupla contagem dos efeitos climáticos ou à diluição do impacto de cada componente, individualmente. Em ditas circunstâncias, a precipitação torna-se um canal mais direto e economicamente interpretável para captar os efeitos regionais do clima sobre o agronegócio, especialmente em um país caracterizado por considerável dependência hídrica na produção agropecuária baseada em monoculturas extensivas.

Sob a óptica analítica, a retirada das variáveis de temperatura também leva a preservar o foco central do estudo nos efeitos do fenômeno El Niño e nos regimes de precipitação regional como principais canais de transmissão climática. Essa escolha contribui para uma narrativa empírica mais clara e coerente, evitando a dispersão do modelo em múltiplas

dimensões climáticas altamente correlacionadas e reforçando a interpretação dos resultados à luz das especificidades regionais do agronegócio brasileiro.

Em assim ocorrendo, a exclusão das variáveis de temperatura regional não implica a negação de sua relevância teórica, mas reflete uma decisão metodológica orientada pela procura de parcimônia³, robustez estatística e clareza interpretativa. Ao concentrar a análise nos choques associados ao El Niño e nas variações de precipitação, o modelo torna-se mais adequado para captar os mecanismos centrais pelos quais a variabilidade climática afeta o desempenho do agronegócio no Brasil.

4.3.2 Especificação do cálculo do índice IboAgro

Atendendo ao primeiro objetivo específico desta pesquisa, este item descreve os procedimentos metodológicos adotados para a formulação do índice IboAgro, desenvolvido com base na metodologia Ibovespa e aplicado exclusivamente às empresas do agronegócio brasileiro listadas na B3.

O índice IboAgro é desenvolvido com o objetivo de representar, sistemática e precisamente, o desempenho econômico-financeiro agregado das empresas do agronegócio brasileiro listadas na B3. Diferentemente de indicadores macroeconômicos tradicionais, que capturam a dinâmica agregada da produção agropecuária, o IboAgro foi concebido para refletir a dimensão corporativa e financeira do setor, incorporando informações de mercado capazes de traduzir a respostas das empresas às condições econômicas, climáticas e institucionais que moldam o agronegócio brasileiro no decurso do tempo.

A formação do índice segue a metodologia básica adotada no cálculo do Ibovespa, com adaptações relevantes que tencionam conferir maior aderência analítica ao setor em estudo. A principal diferenciação consiste na restrição do universo de empresas elegíveis contemplando exclusivamente companhias com atuação expressiva em segmentos estratégicos do agronegócio, tais como grãos, proteínas animais, laticínios, papel e celulose e biocombustíveis. Essa delimitação setorial visa a assegurar que o índice reflita de maneira mais fidedigna a dinâmica econômica do agronegócio, reduzindo a influência de empresas com baixa vinculação produtiva ao setor.

A fórmula geral utilizada no cálculo do IboAgro constitui uma adaptação do modelo de retorno total empregado pela B3 e é assim expressa:

³ Parcimônia refere-se ao princípio metodológico segundo o qual um modelo analítico deve ser formulado com o menor número possível de variáveis e hipóteses, desde que seja capaz de explicar adequadamente o fenômeno em estudo.

(2)

$$IboAgro = \frac{\sum_{i=1}^n (P_{i,t} \cdot Q_{i,t})}{Divisor}$$

em que, $P_{i,t}$ representa o preço da ação da empresa i pertencente ao agronegócio no período t , $Q_{i,t}$ corresponde à quantidade de ações em circulação consideradas para o índice, ajustadas pelo critério de *free float*⁴, o *Divisor* é um fator técnico de ajuste utilizado para manter a continuidade histórica do índice diante de eventos corporativos, como desdobramentos, grupamentos bonificações ou alterações na composição da carteira.

No cálculo do índice IboAgro, o *Divisor* desempenha a função de ajuste responsável por garantir a continuidade da série do índice ao longo do tempo. Como o índice é obtido com procedência no valor de mercado agregado das empresas do agronegócio que compõem a carteira teórica, mudanças na composição da carteira ou a ocorrência de eventos corporativos estão dispostas a alterar o valor agregado das ações, sem representar, necessariamente, uma variação econômica efetiva para os investidores. Para evitar que essas mudanças provoquem saltos artificiais no nível do índice, utiliza-se um divisor de ajuste recalculado sempre que tais eventos ocorrem.

Considerando a expressão geral do índice IboAgro (2), define-se o valor de mercado agregado da carteira como,

(3)

$$MV_t = \sum_{i=1}^n (P_{i,t} \cdot Q_{i,t})$$

em que MV_t é o valor de mercado total da carteira do índice no período t .

Quando ocorre algum evento que altera o valor agregado da carteira sem representar ganho ou perda econômica real, como desdobramentos, grupamentos ou alterações na composição da carteira, o *Divisor* é ajustado de modo que o nível do índice permaneça contínuo entre dois instantes consecutivos. Assim, impõe-se a condição de continuidade do índice,

(4)

$$IboAgro_{t-} = IboAgro_{t+}$$

⁴ *Free float* refere-se à parcela das ações de uma empresa que está efetivamente disponível para negociação no mercado, excluindo participações detidas por controladores, governos ou acionistas estratégicos com intenção de comprido prazo.

o que implica,

$$\frac{MV_{t^-}}{Divisor_{t^-}} = \frac{MV_{t^+}}{Divisor_{t^+}} \quad (5)$$

Com suporte nessa relação, obtém-se a regra de atualização do *Divisor*:

$$Divisor_{t^+} = Divisor_{t^-} \times \frac{MV_{t^+}}{MV_{t^-}}, \quad (6)$$

ou, de forma equivalente,

$$Divisor_{t^+} = \frac{MV_{t^+}}{IboAgro_{t^-}} \quad (7)$$

Esse procedimento garante que ajustes técnicos ou mudanças na carteira não provoquem discontinuidades na série do índice. Ocorrendo assim, a dinâmica do IboAgro passa a refletir apenas as variações efetivas nos preços das ações das empresas do agronegócio consideradas na carteira teórica, preservando a consistência temporal e a comparabilidade do indicador no decurso do tempo analisado.

A composição do IboAgro é revisada a cada quatro meses, de maneira análoga à revisão quadrimestral do Ibovespa. O conjunto de empresas elegíveis, todavia, permanece restrito aos ativos com atuação comprovadamente relevante no agronegócio, selecionados com base em critérios objetivos, como volume médio negociado, frequência de negociação em pregão e representatividade setorial. Essa estratégia metodológica intenta mitigar distorções associadas à entrada e saída recorrente de empresas do setor na composição de índices amplos de mercado, garantindo maior estabilidade, coerência analítica e comparabilidade intertemporal da série.

Tal característica é particularmente relevante para análises de extenso prazo, como a desenvolvida neste estudo, em que a permanência contínua das empresas na composição do índice é essencial para a correta identificação dos efeitos associados aos choques climáticos recorrentes, como os episódios do fenômeno El Niño.

Adicionalmente, o IboAgro é concebido como um índice de retorno total, incorporando os proventos distribuídos pelas empresas, dividendos e juros sobre capital próprio, por meio de ajustes nos preços dos ativos. Essa propriedade enseja refletir de maneira mais fiel

o retorno efetivo do investidor ao comprido do tempo, aspecto crucial para a avaliação da rentabilidade das companhias do agronegócio, especialmente em contextos marcados por elevada volatilidade climática e econômica.

Embora o IboAgro seja construído em nível, preservando sua trajetória histórica e dando oportunidade a comparações intertemporais o desempenho agregado do setor, conforme especificado nas equações 2, 3, 4, 5 6 e 7, sua utilização nas análises econométricas subsequentes requer uma transformação adicional. Considerando que o fenômeno El Niño se caracteriza como um choque exógeno de natureza predominantemente transitória, opta-se por empregar a taxa de variação logarítmica anual do índice como variável independente nos modelos econométricos.

Atendendo ao segundo objetivo específico, o emprego da variação logarítmica do índice IboAgro transporta a captar os efeitos dinâmicos dos choques climáticos sobre o desempenho agregado do setor.

Essa escolha metodológica fundamenta-se na premissa de que choques climáticos tendem a afetar a dinâmica de crescimento, retração ou volatilidade do desempenho financeiro do setor, e não necessariamente o nível acumulado do índice no curso temporal.

Formalmente, o retorno do IboAgro no período t é definido como:

(8)

$$\Delta \ln(IboAgro_t) = \ln(IboAgro_t) - \ln(IboAgro_{t-1})$$

Essa transformação alinha a análise empírica à literatura aplicada sobre mercados financeiros e riscos climáticos, que reconhece o clima como um fator gerador de choques capazes de afetar primordialmente as variações intertemporais dos indicadores econômicos, e não seus níveis estruturais de extenso prazo.

4.3.3 Tratamento da assimetria climática do fenômeno El Niño

A literatura climática e econômica reconhece que os efeitos dos fenômenos El Niño não são simétricos em relação às fases opostas do ciclo do sistema El Niño-Oscilação Sul (ENSO). Episódios de El Niño e La Niña diferem em intensidade, bem como nos mecanismos físicos que afetam os regimes de precipitação, temperatura e, conseqüentemente, o desempenho das atividades econômicas sensíveis ao clima.

Com o objetivo de captar essa assimetria, o *Oceanic Niño Index* (ONI) é decomposto em dois componentes: um associado às anomalias positivas da temperatura da superfície do oceano (ONI⁺), representativas de episódios de El Niño, e outro associado às

anomalias negativas (ONI), relacionadas a episódios de La Niña. Essa decomposição leva a se avaliar se os impactos climáticos sobre o desempenho financeiro do agronegócio diferem conforme a natureza do choque climático, evitando a imposição de uma relação linear restritiva entre o ONI e a variável econômica.

A incorporação dessa assimetria contribui para uma representação mais fiel da dinâmica climática e amplia a capacidade explicativa dos modelos econométricos, ao reconhecer que choques positivos ou negativos do ENSO são propícios a produzir efeitos distintos sobre o setor.

4.3.4 Redução de multicolinearidade das variáveis de precipitação

As variáveis de precipitação regional utilizadas neste ensaio denotam, naturalmente, elevado grau de correlação entre si, uma vez que os regimes pluviométricos das grandes regiões brasileiras são influenciados por fatores climáticos comuns. A inclusão simultânea dessas variáveis em modelos econométricos é capaz de produzir problemas de multicolinearidade, inflacionando os erros-padrão e dificultando a identificação dos efeitos individuais.

Para mitigar esse problema, adotou-se, complementarmente, a Análise de Componentes Principais (ACP)⁵ aplicada às séries de precipitação das cinco regiões. O primeiro componente principal, que concentra a maior parcela da variância conjunta das precipitações regionais, é interpretado como um fator climático agregado de precipitação, representando o comportamento comum dos regimes pluviométricos no Território Nacional.

A agregação das variáveis de precipitação foi realizada com base na análise da matriz de correlação entre as séries regionais. Inicialmente, foram calculados os coeficientes de correlação de Pearson entre todas as variáveis de precipitação consideradas no modelo. Variáveis que denotam níveis elevados de correlação foram agrupadas de modo a reduzir a redundância de informação e minimizar problemas de multicolinearidade. Como critério adicional de validação da agregação proposta, foram avaliados os fatores de inflação da variância (*Variance Inflation Factor* – VIF) nas especificações preliminares do modelo econométrico. A redução dos valores de VIF após a agregação das variáveis foi utilizada como evidência de que o procedimento contribuiu para melhorar a estabilidade estatística do modelo,

⁵ Análise de Componente Principais (ACP) é uma técnica estatística multivariada utilizada para reduzir a dimensionalidade de um conjunto de variáveis correlacionadas, por meio da transformação dessas variáveis originais em menos componentes não correlacionados. Cada componente principal representa uma combinação linear das variáveis originais e captura a maior parcela possível da variância total dos dados, sendo amplamente empregada para síntese de informações e mitigação de problemas de multicolinearidade.

reduzindo a colinearidade entre as variáveis explicativas sem perda significativa de informação sobre o comportamento das precipitações.

4.3.5 *Simulação dos arranjos analíticos*

Atendendo ao terceiro objetivo específico, este item analisa a resposta do agronegócio brasileiro aos episódios do fenômeno El Niño por meio de variados arranjos analíticos, incorporando tanto a intensidade do choque climático global quanto suas manifestações regionais.

A etapa de simulação compreende a aplicação de três arranjos analíticos complementares, denominados Arranjo 1, Arranjo 2 e Arranjo 3, concebidos com o objetivo de avaliar, sob distintas perspectivas, os efeitos do fenômeno El Niño sobre o desempenho econômico-financeiro do agronegócio brasileiro. A utilização de múltiplos arranjos analíticos transportam a explorar distintas modalidades de representação dos choques climáticos e verificar a intensidade dos resultados obtidos ante opções metodológicas.

O Arranjo Analítico 1 considera a magnitude do fenômeno El Niño por meio do índice *Oceanic Niño Index* (ONI), incorporando diretamente como variável explicativa, juntamente com as variáveis regionais de precipitação. Esse arranjo demanda captar o efeito médio e linear do fenômeno climático global sobre a variação do desempenho agregado do agronegócio, representado pelo retorno do IboAgro, controlando simultaneamente pelas heterogeneidades climáticas regionais.

O Arranjo Analítico 2 introduz uma decomposição do índice ONI em componentes associados a episódios positivos e negativos, conduzindo a distinguir os efeitos assimétricos decorrentes de variadas fases do fenômeno El Niño. Essa abordagem reconhece que choques climáticos não afetam o setor de maneira homogênea, capazes de produzir impactos diferenciados conforme a intensidade e o sinal das anomalias térmicas no Oceano Pacífico Equatorial. A simulação desse arranjo possibilita investigar se episódios mais severos ou persistentes produzem respostas distintas no desempenho financeiro do agronegócio.

O Arranjo Analítico 3, a seu turno, incorpora técnicas de redução de dimensionalidade aplicadas às variáveis climáticas regionais, por meio da Análise de decomposição em Componentes Principais (DCP). Nesse caso, as médias anuais de precipitação das cinco grandes regiões brasileiras são sintetizadas em componentes representativos dos padrões climáticos dominantes. Essa estratégia enseja mitigar problemas de multicolinearidade entre variáveis regionais altamente correlacionadas, ao mesmo tempo em que preserva a informação essencial contida nos dados climáticos. A simulação desse arranjo

objetiva avaliar se a utilização de fatores climáticos agregados altera a magnitude ou a significância dos efeitos associados ao El Niño sobre o retorno do IboAgro.

A adoção desses três arranjos analíticos possibilita uma análise mais abrangente e consistente dos impactos climáticos sobre o agronegócio brasileiro, uma vez que combina abordagens diretas, assimétricas e sintéticas de mensuração do choque climático. Desse modo, a comparação entre os resultados obtidos nas simulações contribui para o fortalecimento das inferências empíricas, reduzindo a dependência de única estratégia analítica e ampliando a consistência das conclusões do estudo.

4.4 Especificação do Modelo GVAR

O modelo econométrico adotado neste estudo é o *Global Vector Autoregressive* (GVAR), originalmente proposto por Pesaran, Schuermann e Weiner (2004), cuja principal virtude reside na capacidade de modelar sistemas econômicos interdependentes, captando simultaneamente as dinâmicas internas de cada unidade analisada e os efeitos de choques externos que se propagam globalmente. Tal estrutura é particularmente adequada para o estudo do agronegócio brasileiro, uma vez que as empresas do setor operam em um ambiente fortemente influenciado por fatores climáticos, flutuações de preços internacionais e choques macroeconômicos globais.

Diferentemente dos modelos VAR tradicionais, que tratam as unidades de análise de maneira isolada, o GVAR enseja incorporar explicitamente interações cruzadas de empresas, regiões e mercados, reconhecendo a existência de interdependência estrutural. Conforme destacam Pesaran, Schuermann e Weiner (2004), ignorar tais inter-relações conduz a especificações incorretas e estimativas viesadas, especialmente em contextos caracterizados por elevada integração econômica e financeira. Gutierrez, Piras e Roggero (2014) reforçam esse argumento, quando demonstram que choques em mercados de *commodities* tendem a se propagar de modo assimétrico entre regiões e agentes econômicos, justificando o uso de modelos globais.

Nesse sentido, o GVAR oferece uma estrutura econométrica coerente com a realidade do agronegócio, ao consentir que choques climáticos regionais, como aqueles associados ao fenômeno El Niño, afetem simultaneamente múltiplas empresas, ao mesmo tempo em que incorpora a influência de variáveis globais exógenas, como preços internacionais de *commodities* e condições financeiras externas. A formalização do modelo, bem como a especificação das equações que compõem a estrutura GVAR utilizada nesta pesquisa, estão expressas nos subitens a seguir, nos quais se detalham a estrutura dos modelos VAR específicos

de cada unidade, a incorporação das variáveis globais e o procedimento de agregação que dá origem ao sistema global de equações.

4.4.1 Modelo VARX para cada empresa

A operacionalização do modelo *Global Vector Autoregressive* (GVAR) adotado neste estudo tem início com a estimação de sistemas dinâmicos individuais para cada empresa pertencente ao conjunto analisado, conforme a abordagem metodológica proposta por Perasan (2004). Nessa etapa, inicial, cada empresa é modelada por meio de um sistema autorregressivo vetorial com variáveis exógenas, denominando VARX, cuja função é capturar, de maneira estruturada, a dinâmica interna das variáveis econômico-financeiras e sua interação com choques externos de natureza climática.

O modelo VARX incorpora explicitamente fatores exógenos não determinados endogenamente pelo desempenho financeiro das empresas, mas que exercem influência relevante sobre sua trajetória à proporção do tempo. No contexto deste estudo, tais fatores correspondem aos choques climáticos associados ao fenômeno El Niño, representados tanto pelo ONI quanto pelas médias anuais de precipitação nas cinco grandes regiões brasileiras, Centro-Oeste, Nordeste, Norte, Sudeste e Sul, conforme definido no Quadro 2.

Formalmente, o sistema VARX(p,q) estimado para cada empresa i é representado como:

$$y_{i,t} = c_i + \sum_{j=1}^p A_{ij}y_{i,t} + \sum_{k=0}^q B_{ik}x_{i,t} + \sum_{l=0}^r D_{il}z_{t,-l} + \varepsilon_{i,t} \quad (9)$$

em que $y_{i,t}$ representa o vetor de variáveis endógenas da empresa i no período t , composto pelo índice IboAgro em nível ou, alternativamente, por sua taxa de variação logarítmica anual $\Delta \ln(IboAgro_t)$, conforme a etapa da análise empírica. O vetor $x_{i,t}$ corresponde ao conjunto de variáveis climáticas específicas, formado pelo índice ONI e pelas variáveis de precipitação média regional, que captam a exposição climática das empresas do agronegócio brasileiro. Já o vetor z_t incorpora eventuais variáveis exógenas globais, comuns às unidades, quando aplicável.

Os termos A_{ij} , B_{ik} , D_{il} são matrizes de coeficientes associadas, respectivamente, às defasagens das variáveis endógenas, às variáveis climáticas específicas e às variáveis globais exógenas, enquanto c_i representa o intercepto específico de cada empresa. O termo $\varepsilon_{i,t}$

corresponde ao vetor de resíduos, assumido com média zero e matriz de variância-covariância finita.

A inclusão de defasagens nos componentes endógenos e exógenos do sistema é essencial para capturar a natureza dinâmica dos ajustamentos econômicos no agronegócio, setor no qual os efeitos de choques climáticos tendem a se manifestar de maneira defasada à medida do tempo. Decisões de produção, investimento, financiamento e gestão de risco não respondem instantaneamente às alterações nas condições climáticas, mas se ajustam gradualmente, refletindo ciclos produtivos, contratos financeiros e expectativas dos agentes econômicos (Assad *et al.*, 2002).

Ao empregar como variável dependente a taxa de variação logarítmica do IboAgro, o modelo VARX consente analisar precisamente, de um ponto de vista estatístico, como os choques associados ao El Niño afetam a dinâmica de crescimento, retração ou volatilidade do desempenho financeiro das empresas, em consonância com a literatura que trata o clima como um fator gerador de choques predominantemente transitórios (Perasan *et al.*, 2004). Essa abordagem reduz problemas associados à persistência excessiva das séries em nível e assegura maior coerência econômica na interpretação dos coeficientes estimados.

Após a estimação dos sistemas VARX individuais, as equações específicas de cada empresa são posteriormente integradas em um sistema global coerente, formando a estrutura completa do modelo GVAR. Esse procedimento possibilita analisar os efeitos diretos dos choques climáticos sobre o desempenho financeiro das empresas do agronegócio, bem assim os mecanismos de propagação e interdependência de variadas unidades, regiões e mercados, oferecendo uma visão abrangente e sistemática da dinâmica do setor em um contexto de elevada integração econômica e climática (Perasan *et al.*, 2014).

4.4.2 Agregação e estabelecimento do sistema GVAR

Uma vez estimados os modelos VARX individuais para cada empresa da amostra, totalizando 11 modelos VARX, correspondentes às 11 empresas do agronegócio selecionadas para compor a base de análise, o passo subsequente consiste na agregação dessas equações em um sistema global coerente, formando o modelo GVAR. Essa etapa constitui um elemento central da metodologia adotada, pois conduz a integrar as dinâmicas específicas de cada empresa em arcabouço econométrico único, capaz de capturar a propagação de choques entre unidades economicamente interdependentes. Diferentemente de uma simples justaposição de modelos individuais, o procedimento para estabelecer o GVAR combina os VARX específicos de cada unidade em um sistema integrado de equações, no qual as variáveis externas de cada

empresas incorporam informações provenientes das demais unidades do sistema. Conforme destacam M. Hashem Pesaran, Til Schuermann e Scott M. Weiner (2004), esse procedimento enseja representar consistentemente as inter-relações dos agentes econômicos, preservando a estrutura de dependência cruzada entre as unidades analisadas. Sendo assim, a agregação dos 11 modelos VARX individuais resulta em um sistema econométrico global capaz de captar tanto as dinâmicas internas de cada empresa quanto os efeitos de choques que se propagam entre as distintas organizações do agronegócio consideradas na amostra.

A agregação inicia-se com a feitura das variáveis externas específicas $y_{i,t}^*$, definidas como combinações lineares das variáveis endógenas das demais empresas do sistema. Formalmente, essas variáveis são obtidas por meio de matrizes de ponderação W_i , de modo que:

$$y_{i,t}^* = \sum_{j \neq i} w_{ij} y_{j,t} \quad (10)$$

em que w_{ij} representa o peso atribuído à influência da empresa j sobre a empresa i , com a restrição de que $\sum_{j \neq i} w_{ij} = 1$. No ensaio sob sustentação, tais pesos refletem a exposição relativa das empresas a fatores comuns do agronegócio, como condições climáticas regionais e choques de mercado, seguindo a abordagem adotada por Gutierrez, Piras e Roggero (2014) em estudos aplicados a mercados de *commodities*.

A incorporação dessas variáveis externas deixa que cada modelo VARX individual internalize informações provenientes do sistema como um todo, reconhecendo que as decisões e os resultados econômicos de uma empresa não são determinados exclusivamente por fatores peculiares. Essa estrutura está em consonância com a literatura econométrica que enfatiza a importância de tratar explicitamente a dependência transversal em modelos dinâmicos, evitando vieses decorrentes da omissão de inter-relações relevantes (Gujarati; Porter, 2011).

Após a definição das variáveis externas específicas, os modelos VARX individuais são empilhados para formar o sistema global. Esse procedimento resulta em uma representação matricial do GVAR, expressa compactamente como:

$$G(L)y_t = a_0 + a_1 t + H(L)d_t + u_t \quad (11)$$

em y_t é o valor global que reúne todas as variáveis endógenas das empresas do sistema, $G(L)$ é uma matriz polinomial em defasagens que incorpora tanto os efeitos autorregressivos internos quanto as interdependências entre as unidades, d_t representa o vetor de variáveis exógenas globais, e u_t é o vetor de erros do sistema. Com essa formação, analisam-se, de maneira integrada, os efeitos diretos e indiretos de choques climáticos e econômicos sobre o conjunto das empresas do agronegócio.

Característica relevante do GVAR é que, embora o sistema global seja de alta dimensão, sua estimação é viabilizada pela decomposição inicial em modelos VARX de menor porte. Essa estratégia reduz significativamente a complexidade computacional e contorna problemas associados à estimação direta de grandes sistemas VAR, conforme discutido por Perasan *et al.* (2004). Demais disso, essa abordagem preserva a heterogeneidade estrutural entre as empresas, ensejando que cada unidade expresse dinâmicas próprias, ao mesmo tempo em que participa de um sistema interconectado.

A agregação do GVAR também possibilita a realização de exercícios analíticos de interesse econômico, como a análise de funções impulso-resposta globais e a decomposição da variância do erro de previsão. Com tais ferramentas, é dado avaliar-se o modo como choques em variáveis climáticas regionais, como temperatura, precipitação e o índice ONI, se propagam no tempo entre as empresas do agronegócio, afetando indicadores de rentabilidade, liquidez e eficiência operacional. Tal abordagem é particularmente relevante em um setor caracterizado por elevada sensibilidade a eventos climáticos extremos e por intensiva integração produtiva e financeira.

A agregação do GVAR perfilhada nesta Dissertação de Mestrado oferece uma estrutura econométrica robusta para investigar a transmissão de choques climáticos e econômicos no agronegócio brasileiro, articulando níveis microeconômicos e globais em único modelo analítico. Essa estratégia amplia o alcance das análises tradicionais e contribui para uma compreensão maior das interdependências que moldam o desempenho das organizações do setor à proporção do tempo.

4.4.3 Testes de estabilidade, seleção da ordem de defasagem e diagnóstico do modelo

A estimação de modelos dinâmicos multivariados, como o VARX e o GVAR, requer a observância rigorosa de procedimentos metodológicos que assegurem a validade estatística e a consistência econômica dos resultados. Conforme enfatizado por Gujarati e Porter (2011), a escolha inadequada da ordem de defasagem, a instabilidade do sistema ou a existência de resíduos malcomportados são capazes de comprometer severamente a interpretação dos

coeficientes e das análises de impulso-resposta. Assim, esta experimentação adota um conjunto de testes e critérios amplamente consolidados na literatura econométrica para garantir a robusteza das estimativas.

A seleção da ordem de defasagem dos modelos VARX individuais constitui o primeiro passo desse processo. Considerando-se que o número excessivo de defasagens é passível de resultar em perda de graus de liberdade e aumento da variância dos estimadores, enquanto um número insuficiente é suscetível de produzir autocorrelação serial nos resíduos, optou-se pela utilização de critérios de informação. Em consonância com Gujarati e Porter (2011), foram empregados o Critério de Informação de Akaike (AIC)⁶, o Critério de Informação de Schwarz-Bayesian (BIC)⁷ e o Critério de Hannan-Quinn (HQ)⁸, definidos respectivamente, como:

(12)

$$AIC = \ln|\Sigma| + \frac{2k}{T}$$

(13)

$$BIC = \ln|\Sigma| + \frac{k \ln T}{T}$$

(14)

$$HQ = \ln|\Sigma| + \frac{2k \ln(\ln T)}{T}$$

em que Σ representa a matriz de variância-covariância dos resíduos, k o número de parâmetros estimados e T o tamanho da amostra. A escolha final da ordem de defasagem levou em consideração a convergência entre os critérios, privilegiando especificações parcimoniosas e estatisticamente adequadas.

⁶ Critérios de Informação de Akaike (AIC) significam uma medida estatística utilizada para seleção de modelos, que avalia o equilíbrio entre qualidade de ajuste e parcimônia. O AIC penaliza modelos excessivamente complexos, sendo calculado com suporte na função de verossimilhança e do número de parâmetros estimados, de modo que valores menores indicam modelos com melhor capacidade explicativa relativa.

⁷ Critério de Informação de Schwarz-Bayesian (BIC) é uma medida estatística utilizada para seleção de modelos, que avalia o compromisso entre qualidade e ajuste de parcimônia, aplicando uma penalização mais severa para modelos com maior número de ajustes de parâmetros. O BIC é calculado com base na função de verossimilhança e no tamanho da amostra, sendo que valores menores indicam modelos preferíveis em termos de consistência estatística.

⁸ Critério de Hannan-Quinn (HQ) é uma medida estatística utilizada para seleção de modelos autorregressivos, que equilibra qualidade de ajuste a parcimônia por meio de uma penalização intermediária entre os critérios de Akaike (AIC) e Schwarz-Bayesian (BIC). O HQ baseia-se na função de verossimilhança e no número de parâmetros estimados, sendo que valores menores indicam modelos mais adequados.

Uma vez definida a estrutura dinâmica, procedeu-se à avaliação da estabilidade dos modelos VARX e do sistema GVAR agregado. De acordo com Gujarati (2011), um sistema autorregressivo é considerado estável se todas as raízes do polinômio característico associado ao modelo estiverem localizadas dentro do círculo unitário. Essa condição assegura que choques exógenos tenham efeitos transitórios e que o sistema convirja para o equilíbrio no longo prazo. No estudo ora relatoriado, a estabilidade foi verificada por meio da análise dos autovalores da matriz companheira⁹, garantindo que as funções impulso-resposta e a decomposição da variância do erro de previsão fossem economicamente interpretáveis.

O diagnóstico dos resíduos constitui outro elemento central da validação do modelo. Inicialmente, foi testada a ausência de autocorrelação serial dos erros, utilizando-se testes do tipo Portmanteau¹⁰ e Multiplicador de Lagrange (LM) multivariado¹¹, conforme recomendado por Gujarati e Porter (2011). A não rejeição da hipótese nula de ausência de autocorrelação indica que a dinâmica temporal do modelo foi adequadamente capturada pelas defasagens incluídas, reduzindo o risco de especificação incorreta.

Adicionalmente, avaliou-se se havia heterocedasticidade nos resíduos, uma vez que modelos aplicados a dados financeiros e econômicos, frequentemente, exprimem variância não constante ao correr do tempo. Embora o GVAR expresse tolerância a formatos moderados de heterocedasticidade, a sua identificação permanece relevante para a correta interpretação dos resultados e eventual adoção de procedimentos de inferência ajustados. Nesse sentido, testes de heterocedasticidade multivariada foram empregados como instrumento complementar do diagnóstico.

Embora a normalidade dos resíduos não seja uma condição estritamente necessária para consistência dos estimadores em modelos VAR, Gujarati (2011) evidencia que sua verificação contribui para a confiabilidade de testes estatísticos e intervalos de confiança. Desse modo, foram realizados testes de normalidade multivariada, por via dos quais se avalia o grau de aderência dos resíduos à distribuição normal e, quando pertinente, sobra fundamentada a adoção de procedimentos inferenciais alternativos.

⁹ Matriz companheira é uma representação matricial utilizada em modelos autorregressivos, especialmente em sistemas VAR, que reescreve o modelo em forma de primeira ordem. Essa matriz organiza os coeficientes das equações defasadas de modo a permitir a análise da estabilidade do sistema, da dinâmica temporal das variáveis e da obtenção de respostas a impulsos e decomposição da variância dos erros de previsão.

¹⁰ O teste Portmanteau avalia conjuntamente a significância das autocorrelações dos resíduos em múltiplas defasagens.

¹¹ O teste Multiplicador de Lagrange (LM) multivariado examina a existência de autocorrelação residual em defasagens específicas.

A combinação criteriosa de testes de seleção de defasagens, verificação de estabilidade e diagnóstico dos resíduos assegura que o modelo GVAR estimado neste estudo exprima fundamentos econométricos sólidos. Essa estratégia metodológica fortalece a confiabilidade das análises subsequentes, em especial, aquelas relacionadas à transmissão de choques climáticos e econômicos sobre o desempenho das empresas do agronegócio brasileiro, alinhando-se às boas práticas recomendadas pela literatura econométrica clássica e contemporânea.

4.4.4 Funções Impulso-Resposta e Decomposição da Variância do Erro de Previsão

Atendendo ao terceiro objetivo específico, com a utilização de funções impulso-resposta e da decomposição da variância do erro de previsão, mensuram-se a magnitude, a persistência e as diferenças regionais na resposta do agronegócio brasileiro aos choques associados ao El Niño.

Uma vez asseguradas a estabilidade do sistema e a adequação estatística dos modelos VARX individuais e do GVAR agregado, procede-se à análise dinâmica dos choques por meio das Funções Impulso-Resposta (FIR)¹² e da Decomposição da Variância do Erro de Previsão (DVEP)¹³. Essas ferramentas constituem instrumentos centrais para a interpretação econômica dos modelos autorregressivos multivariados, pois, por seu intermédio, analisa-se como perturbações exógenas afetam as variáveis endógenas no curso do tempo, bem como se mensura a importância relativa de cada choque na explicação da variabilidade do sistema (Gujarati; Porter, 2011).

As funções impulso-resposta descrevem a trajetória temporal das variáveis endógenas após a ocorrência de um choque unitário em uma variável específica do sistema, mantendo-se constantes as demais inovações. No contexto do modelo GVAR, essa análise assume particular relevância, uma vez que os choques são passíveis de se propagar dentro de uma mesma organização empresarial, bem como entre distintas empresas e regiões, refletindo a interdependência estrutural do agronegócio. Conforme destacam Pesaran, Schuermann e

¹² Funções Impulso-Resposta (FIR) são ferramentas analíticas utilizadas em modelos dinâmicos, como VAR e GVAR, que descrevem a trajetória temporal das variáveis endógenas em resposta a um choque exógeno unitário em uma das variáveis do sistema. As FIR permitem avaliar a magnitude, a direção e a persistência dos efeitos dos choques no decurso temporal, sendo amplamente empregadas na análise de interdependências econômicas e na avaliação dos impactos dinâmicos.

¹³ Decomposição da Variância do Erro de Previsão (DVEP) é uma técnica empregada em modelos dinâmicos, como VAR e GVAR, com vistas a identificar a proporção da variância do erro de previsão de uma variável atribuível a choques próprios e a choques provenientes das demais variáveis do sistema, ao longo de variados horizontes temporais. A DVEP é utilizada para avaliar a importância relativa das fontes de incertezas e os mecanismos de transmissão dos choques no modelo.

Weiner (2004), pelas FIR globais, captam-se tanto os efeitos diretos quanto os de ordem indireta (*spillovers*), oferecendo uma visão integrada da dinâmica de transmissão de choques.

Formalmente, a resposta de uma variável endógena y_{t+h} a um choque estrutural em ε_t é representada, em sua forma geral, como:

$$IRF(h) = \frac{\partial y_{t+h}}{\partial \varepsilon_t} \quad (15)$$

em que h representa o horizonte temporal da resposta. No estudo relatado neste passo, as funções impulso-resposta são utilizadas para avaliar, por exemplo, como choques climáticos, associados a variações na precipitação e no índice ONI, afetam indicadores econômico-financeiros das empresas do agronegócio, como rentabilidade, liquidez e crescimento patrimonial, no correr de variados horizontes temporais.

Considerando as limitações dos esquemas tradicionais de identificação baseados em ordenações recursivas, optou-se pela utilização de funções impulso-resposta generalizadas, conforme proposto por Pesaran e Shin (1998). Essa abordagem exprime a vantagem de ser invariante à ordenação das variáveis no sistema, característica especialmente desejável em modelos de alta dimensão como o GVAR. Gujarati e Porter (2011) ressaltam que essa estratégia reduz arbitrariedades na identificação dos choques e aumenta a força das inferências econômicas.

Complementarmente às funções impulso-resposta, a decomposição da variância do erro de previsão dá a oportunidade de quantificar a contribuição relativa de cada choque para a variabilidade das variáveis endógenas *pro rata temporis*. Em termos formais, a DVEP expressa a proporção da variância do erro de previsão de $y_{i,t+h}$ atribuída a choques específicos do sistema, representada como:

$$V D_{i,j}(h) = \frac{Var(\varepsilon_{j,t} \rightarrow y_{i,t+h})}{Var(y_{i,t+h})} \quad (16)$$

em que $V D_{i,j}(h)$ indica a parcela da variância i explicada por choques na variável j no horizonte h . Essa decomposição fornece evidências sobre a relevância relativa dos fatores climáticos, financeiros e globais na determinação do desempenho das empresas à medida da passagem do tempo.

No contexto do agronegócio, por meio da DVEP, se identifica se a dinâmica de indicadores como o IboAgro, o retorno sobre ativos ou o giro do ativo é predominantemente explicada por choques climáticos regionais, por fatores internos às empresas ou por choques externos globais, como variações nos preços internacionais de *commodities*. Estudos como o de Gutierrez, Piras e Roggero (2014) demonstram que essa abordagem é particularmente útil para compreender a natureza e a persistência dos efeitos de choques em mercados de *commodities*, caracterizados por elevada volatilidade e intensa interconexão.

Em síntese, a utilização conjunta das funções impulso-resposta e da decomposição da variância do erro de previsão consente que se explorem de maneira aprofundada os mecanismos de transmissão de choques no modelo GVAR estimado. Essas ferramentas ampliam a capacidade analítica do estudo, ao revelarem a direção e a intensidade dos impactos, bem assim sua persistência temporal e sua importância relativa, oferecendo subsídio para a interpretação dos efeitos do fenômeno El Niño e de outros choques macroeconômicos sobre o desempenho das empresas do agronegócio brasileiro.

5 RESULTADOS E DISCUSSÃO

Esta seção demonstra e discute os resultados empíricos obtidos com amparo na construção do índice IboAgro e na estimação de modelos econométricos que relacionam o desempenho agregado do agronegócio brasileiro, sintetizado pelo IboAgro, ao fenômeno ENSO, medido pelo *Oceanic Niño Index* (ONI), incorporando controles climáticos por macrorregião do Brasil (precipitação). A estratégia foi desenhada para responder, direta e organizadamente, aos objetivos, respeitando a sequência: (i) construção e caracterização do IboAgro; (ii) avaliação do impacto do El Niño sobre o desempenho econômico-financeiro agregado capturado pelo índice; e (iii) investigação da resposta do setor a episódios do fenômeno, com ênfase na heterogeneidade regional e nos canais climáticos associados.


Os modelos foram estimados por Mínimos Quadrados Ordinários (MQO) com erros HAC (Newey-West), a fim de conferir maior confiabilidade inferencial de heterocedasticidade e autocorrelação potencialmente existentes em séries anuais extensas. A variável dependente adotada nos modelos dinâmicos é o retorno do IboAgro, mensurado como $\Delta \ln(IboAgro)$, o que dá oportunidade a interpretar os coeficientes como variações aproximadas em termos percentuais, com maior adequação às propriedades de estacionariedade requeridas para inferência em séries temporais.

5.1 Cálculo, trajetória e propriedades empíricas do IboAgro (atendendo ao Objetivo Específico 1)

O primeiro objetivo específico desta pesquisa consiste em realizar o cálculo de um índice representativo do agronegócio brasileiro, agregando informações econômico-financeiras de empresas do setor listadas na bolsa de valores. A motivação central desta etapa é produzir um indicador sintético capaz de refletir, integradamente, o comportamento do desempenho corporativo do agronegócio à medida do tempo, permitindo examinar, em seguida, sua sensibilidade a choques climáticos de grande escala.

A primeira evidência relevante é a própria trajetória temporal do IboAgro em nível (Gráfico 2), que revela oscilações marcadas, com períodos de expansão e retração compatíveis com mudanças no contexto macroeconômico, setorial e climático.

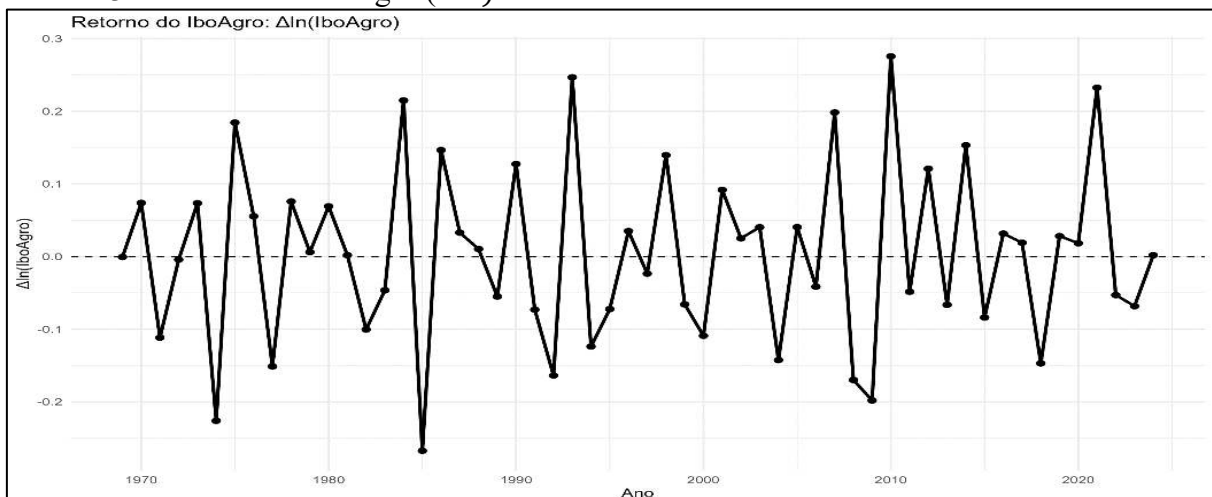
Gráfico 2 – Evolução do IboAgro em nível no Brasil (1968-2024).



Fonte: Elaborado pelo autor.

A leitura do nível do índice é importante para descrever a evolução histórica do desempenho agregado, mas, do ponto de vista econométrico, a análise dinâmica se torna mais precisa quando se observa a variação logarítmica anual, que reduz efeitos de escala e facilita comparações intertemporais.

É observável no Gráfico 2 a existência de ciclos e mudanças de tendência. Com séries em nível, frequentemente, todavia, mostram persistência elevada, e a análise dos choques e respostas se beneficia do uso de uma medida de retorno. Por isso, a segunda evidência essencial é a série $\Delta \ln(IboAgro)$, no Gráfico 3, que expressa a variação percentual aproximada do índice de um ano para o outro.

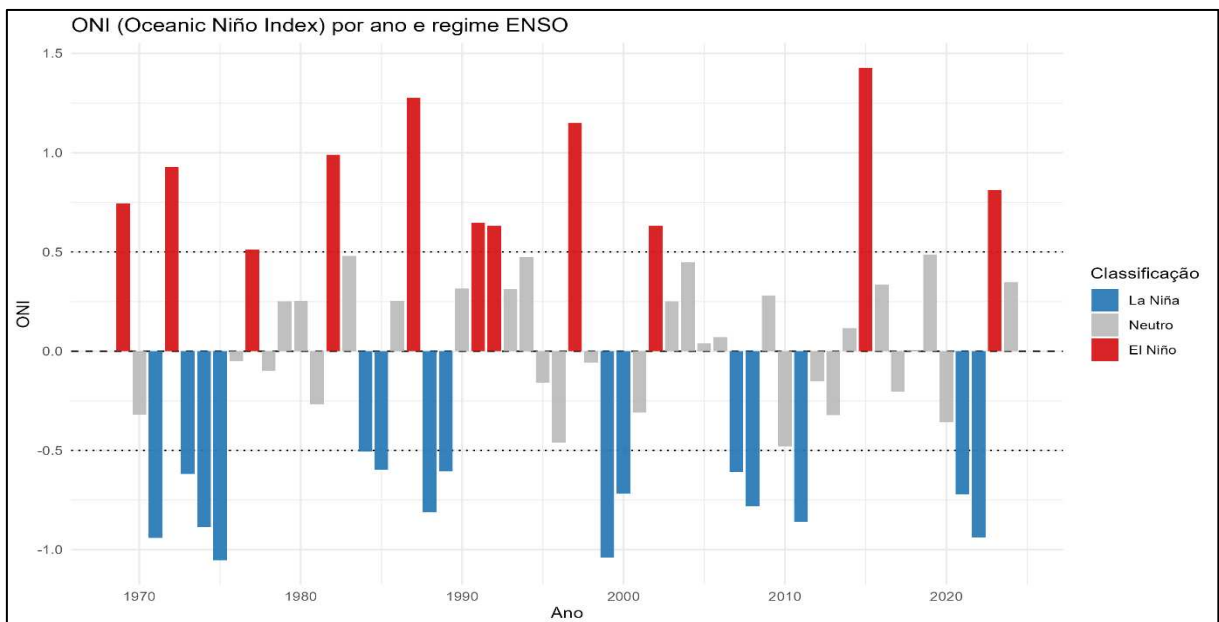
Gráfico 3 – Retorno do IboAgro ($\Delta \ln$).

Fonte: Elaborado pelo autor.

A série de retorno oscila em torno de zero, o que é esperado em transformações em primeira diferença logarítmica e, em termos substantivos, indica alternância de choques positivos e negativos no desempenho agregado do setor no decorrer do tempo. Essa medida concentra a atenção nos movimentos de curto prazo do índice, precisamente o tipo de dinâmica que se pretende relacionar com eventos ENSO.

Para caracterizar o comportamento do ONI no mesmo horizonte temporal e, simultaneamente, oferecer uma leitura intuitiva dos regimes ENSO, o trabalho classifica o ONI anual em três estados: El Niño ($ONI \geq 0,5$), La Niña ($ONI \leq -0,5$) e Neutro.

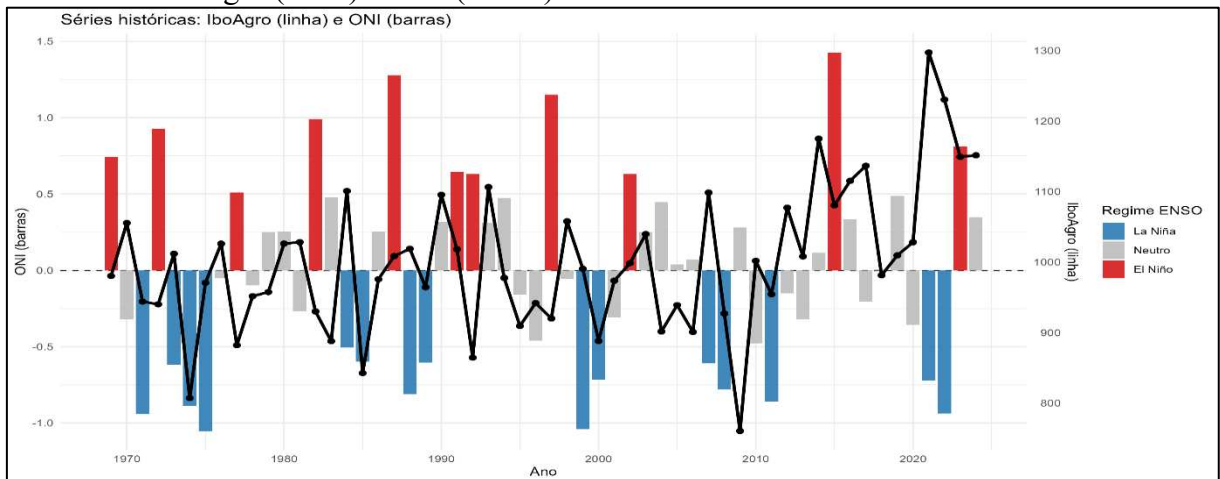
Gráfico 4 – ONI por ano, com classificação ENSO (El Niño / La Niña / Neutro).



Fonte: Elaborado pelo autor.

Para possibilitar uma leitura integrada entre o índice de desempenho do agronegócio e o indicador climático, é particularmente informativo indicar as duas séries no mesmo quadro (Gráfico 5), ONI em barras e IboAgro como linha (com eixo secundário). Essa visualização não substitui a análise econométrica, mas organiza a intuição, embora não esteja muito claro, no gráfico, evidenciar possíveis coincidências temporais entre fases do ENSO e variações no desempenho agregado.


Gráfico 5 – IboAgro (linha) e ONI (barras).



Fonte: Elaborado pelo autor.

Como o objetivo do trabalho não é apenas relacionar ONI e desempenho, mas também incorporar o clima regional como canal e controle, é necessário caracterizar o comportamento das variáveis climáticas conforme a região (Gráfico 6). O banco utilizado contempla precipitação média anual para Centro-Oeste, Nordeste, Norte, Sudeste e Sul. Esses elementos são fundamentais para: (i) controlar efeitos climáticos domésticos propícios a afetar diretamente o agronegócio; e (ii) investigar heterogeneidade espacial, condizente com a natureza regionalmente diferenciada dos impactos do ENSO.

Gráfico 6 – Precipitação média anual, conforme a região.



Fonte: Elaborado pelo autor.

Em conjunto, essas evidências atendem ao primeiro objetivo específico, quando denotam o índice calculado e sua dinâmica, além de estabelecer o pano de fundo necessário para interpretar a etapa econométrica: o IboAgro como variável sintética de desempenho e o ONI e a precipitação regional como explicações potenciais para a sua variação anual.

5.2 Impacto do fenômeno El Niño (ONI) sobre o desempenho agregado do agronegócio (IboAgro), com controles climáticos regionais (Atendendo ao Objetivo Específico 2)

O segundo objetivo específico demanda por analisar o impacto do fenômeno sobre o desempenho econômico-financeiro do agronegócio, aqui mensurado de modo agregado pelo IboAgro. Para isso, estima-se inicialmente um arranjo analítico (Arranjo Analítico 1) em que o retorno do índice ($\Delta \ln(IboAgro)$) é explicado por: ONI contemporâneo, ONI defasado (t-1) e um conjunto de controles climáticos regionais (precipitação por macrorregião).

5.2.1 Resultados do Arranjo Analítico 1 (dinâmico com ONI e precipitação, conforme a região)

A tabela 1 reporta-se às estimativas com erros HAC (Newey-West), com defasagem $lag = 3$, conforme parametrização.

Tabela 1 – Estimação do impacto do fenômeno El Niño e da precipitação regional sobre a variação do índice IboAgro (Arranjo Analítico 1 – erros-padrão HAC/Newey-West).

Variável	Estimativa	Erro-padrão (HAC)	Estatística t	p-valor
(Intercepto)	-0,79998	1,36697	-0,5852	0,5615
ONI	-0,04849	0,02231	-21741	0,0352
ONI _(t-1)	0,01281	0,01884	0,6799	0,5002
prec_CO	-0,000114	0,000178	-0,6402	0,5254
prec_NE	-0000272	0,000117	-23269	0,0247
prec_N	0,000130	0,000113	1,1494	0,2567
prec_SE	-000283	0,0000916	-30893	0,0035
prec_S	0,0000617	0,0000625	0,9871	0,3291

Diagnóstico do Arranjo Analítico 1: $n = 56$; $R^2 = 0,4969$; $R^2_{ajust.} = 0,3565$; $AIC = -87,9163$; $BIC = -59,5613$.

Fonte: Elaborada pelo autor.

O resultado mais diretamente associado ao objetivo do estudo é o coeficiente do ONI contemporâneo, que se mostra negativo e estatisticamente significativo ao nível de 5%. Em termos substantivos, isso indica que valores mais elevados de ONI, associados a condições de El Niño, estão relacionados a uma redução do retorno anual do IboAgro, mesmo após controlar por precipitação regionais. Como a variável dependente está em $\Delta \ln$, a magnitude estimada sugere que um aumento de 1 (uma) unidade no ONI está associado, aproximadamente, a uma variação de -4,85% no retorno do índice (interpretação aproximada em termos percentuais), *ceteris paribus*.


Já o termo defasado ONI_(t-1) não é estatisticamente significativo, o que sugere que, condicionadas as variáveis do modelo, o efeito relevante do ENSO sobre o desempenho agregado do agronegócio aparece com maior intensidade no próprio ano, e não como persistência sistemática no ano seguinte. Esse achado é consistente com a interpretação de que

choques climáticos são capazes de afetar rapidamente expectativas, custos, produtividade e dinâmica de preços em cadeias agroindustriais, com transmissão relativamente contemporânea para indicadores agregado de desempenho.

No que se refere aos controles climáticos regionais, duas variáveis de precipitação se destacam com significância estatística: *prec_NE* (Nordeste) e *prec_SE* (Sudeste), ambas com coeficientes negativos e significativos, embora de magnitude reduzida. Esse resultado sugere, no período analisado, que aumentos na precipitação nessas regiões estão associados a reduções do retorno do IboAgro, mantidas constantes as demais variáveis incluídas na especificação econométrica. Tal relação não deve ser interpretada de modo mecanicista; precipitação elevada é passível de capturar, por exemplo, episódios de excesso hídrico, desorganização logística, elevação de perdas pós-colheita, impactos sobre sanidade e qualidade, e choques de oferta em segmentos específicos.

Para contribuir para a interpretação visual dos resultados, a dispersão entre ONI e $\Delta \ln(IboAgro)$ é apresentada no Gráfico 7 de tendência linear.

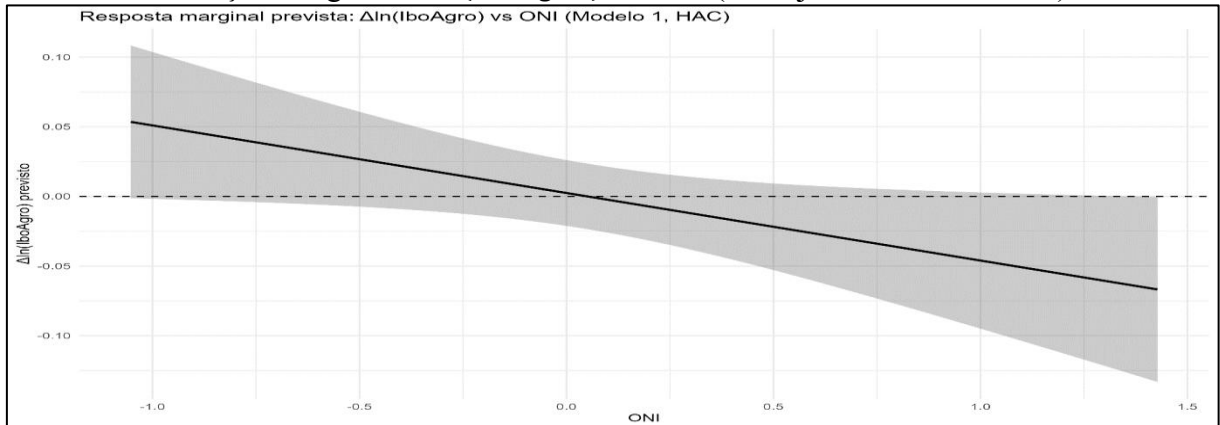
Gráfico 7 – Dispersão: $\Delta \ln(IboAgro)$ vs ONI (com tendência linear)



Fonte: Elaborado pelo autor.

A visualização reforça a inclinação negativa estimada no modelo, ao sugerir que valores positivos do ONI (associados ao El Niño) se concentram mais frequentemente em regiões de retorno menor, ainda que com dispersão relevante, fato esperado, dado que o desempenho do agronegócio é afetado por múltiplos fatores econômicos, institucionais e setoriais além do clima.

Para tornar a leitura econômica ainda mais direta, o *script* gera a predição marginal do retorno em função do ONI, mantendo as demais variáveis constantes em seus valores médios.

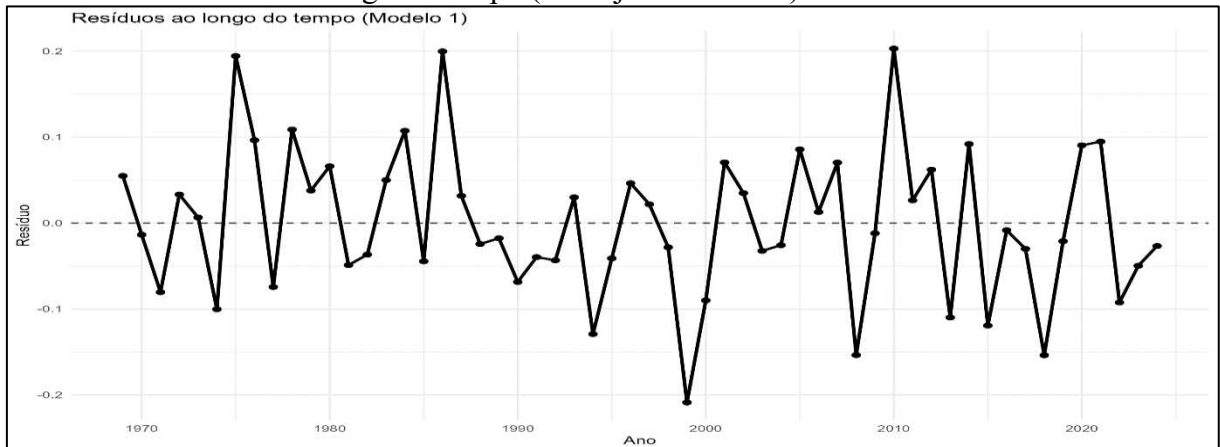
Gráfico 8 – Predição marginal: $\Delta \ln(IboAgro)$ vs ONI (Arranjo Analítico 1, HAC)

Fonte: Elaborado pelo autor.

O Gráfico 8 de predição marginal sintetiza o resultado central do Arranjo Analítico 1: a inclinação negativa indica que, ao se mover para valores mais altos do ONI, a resposta prevista do retorno do IboAgro se reduz, com intervalo de confiança que reflete a incerteza inferencial sob HAC.

Como verificação adicional da estabilidade e do comportamento dos resíduos, mostra-se a série temporal dos resíduos do Arranjo Analítico 1.

Gráfico 9 – Resíduos ao longo do tempo (Arranjo Analítico 1)



Fonte: Elaborado pelo autor.

A análise residual é útil para identificar episódios extremos, possíveis quebras estruturais e períodos em que choques não observados dominaram o comportamento do índice. Esse diagnóstico é particularmente relevante em séries longas, nas quais mudanças de regime econômico e institucional são suscetíveis de coexistir com choques climáticos.

5.3 Resposta a episódios ENSO, assimetrias e heterogeneidade regional, evidências de canal climático (Atendendo ao Objetivo Específico 3)

O terceiro objetivo específico propõe investigar a resposta do setor do agronegócio a episódios do fenômeno e examinar a sensibilidade climática entre as regiões. Para atender a esse objeto, a análise avança em duas direções complementares: (i) assimetria entre eventos de El Niño e La Niña; e (ii) exploração dos canais climáticos via relações entre ONI e variáveis regionais de precipitação.

5.3.1 Assimetria ENSO: ONI positivo (El Niño) versus ONI negativo (La Niña)

O Arranjo Analítico 2 decompõe o ONI em duas componentes: ONI_pos (valores positivos, El Niño) e ONI_neg (valores negativos, La Niña). Essa especificação permite testar se a sensibilidade do retorno do IboAgro é simétrica em torno de zero ou se eventos positivos e negativos do ENSO produzem respostas distintas.

Tabela 2 – Arranjo Analítico 2 (HAC/Newey-West): Resultados da regressão $\Delta \ln(IboAgro)$ com correção HAC (Newey-West)

Variável	Estimativa	Erro-padrão (HAC)	Estatística t	p-valor
(Intercepto)	-0,44392	1,12756	-0,3937	0,6958
ONI_pos	-0,11688	0,03220	-3,6300	0,0007
ONI_neg	0,04062	0,06386	0,6360	0,5281
prec_CO	-0,000145	0,000163	-0,8902	0,3783
prec_NE	-0,000224	0,000106	-2,1025	0,0414
prec_N	0,0000738	0,000102	0,7264	0,4715
prec_SE	-0,000269	0,0000792	-3,3890	0,0015
prec_S	0,0000674	0,0000609	1,1070	0,2744

Diagnóstico do Arranjo Analítico 1: $n = 56$; $R^2 = 0,5317$; $R_{ajust.}^2 = 0,4010$; $AIC = -91,9335$; $BIC = -63,5786$.

Fonte: Elaborada pelo autor.

O resultado é particularmente expressivo: ONI_pos apresenta coeficiente negativo e altamente significativo, enquanto ONI_neg não é estatisticamente significativo. Em termos interpretativos, isso sugere que o efeito adverso do ENSO sobre o desempenho do agronegócio agregado é concentrado nos episódios de El Niño, ao passo que condições de La Niña, pelo menos na média do período e sob os controles incluídos, não se traduzem em efeito estatisticamente detectável sobre o retorno do IboAgro.

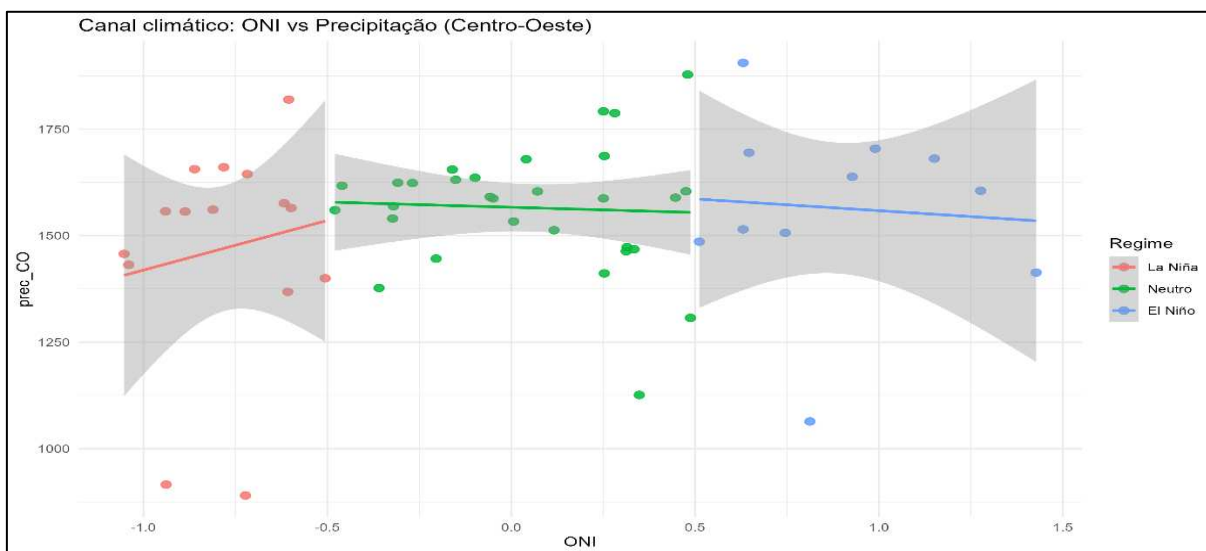
Essa evidência atende diretamente ao objetivo de investigar a resposta do setor a episódios ENSO, pois sustenta a hipótese de assimetria: o agronegócio, tal como capturado pelo índice agregado, mostra-se mais vulnerável a choques associados ao aquecimento anômalo das águas do Pacífico (El Niño) do que a choques associados ao resfriamento (La Niña). Ademais, o Arranjo Analítico 2 expressa desempenho global levemente superior em ajuste (R^2 e critérios

de informação), o que é coerente com a ideia de que tratar a assimetria melhora a capacidade explicativa do modelo.

5.3.2 Canais climáticos e heterogeneidade regional: ONI versus precipitação por macrorregião

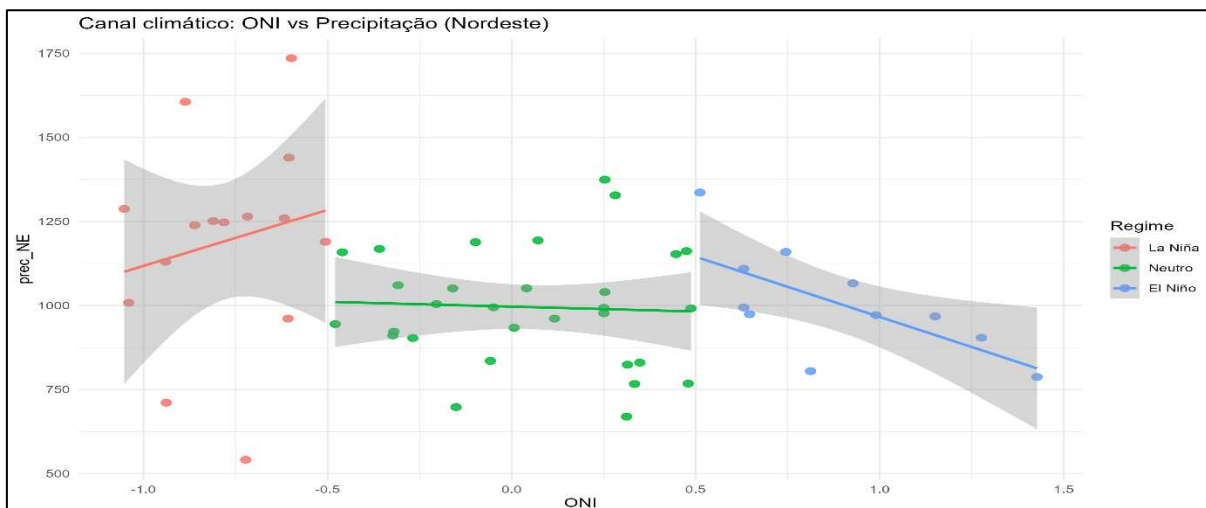
Para aprofundar a interpretação econômica e climática, e não restringir a análise a coeficientes em regressões do retorno, o trabalho explora explicitamente o canal climático por meio de gráficos que relacionam ONI e precipitação em cada região. Essa etapa é relevante porque o ENSO não afeta o Território Brasileiro de modo homogêneo: a transmissão climática se dá por padrões regionais diferenciados, e tais padrões, por sua vez, são propícios a afetar produtividade, custos e riscos nas cadeias agroindustriais.

Gráfico 10 – ONI vs precipitação, conforme a região. Centro-Oeste.



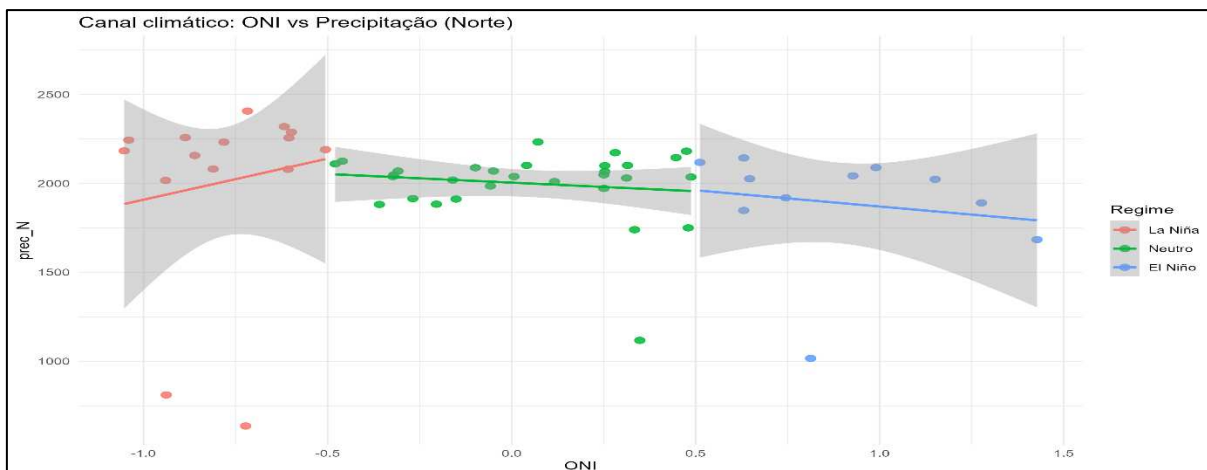
Fonte: Elaborado pelo autor.

Gráfico 11 – ONI vs precipitação, conforme a região. Nordeste.




Fonte: Elaborado pelo autor.

Gráfico 12 – ONI vs precipitação, conforme a região. Norte




Fonte: Elaborado pelo autor.

Gráfico 13 – ONI vs precipitação, conforme a região. Sudeste



Fonte: Elaborado pelo autor.

Gráfico 14 – ONI vs precipitação, conforme a região. Sul



Fonte: Elaborado pelo autor.

Esses gráficos assentem identificar se a precipitação regional responde sistematicamente às variações do ONI, e em que medida essa resposta parece diferir entre regimes (El Niño, La Niña e Neutro). Essa leitura é importante, pois ajuda a contextualizar por que determinadas variáveis de precipitação aparecem como estatisticamente relevantes nos modelos de retorno.

A leitura conjunta dos resultados econométricos e desses gráficos de canal climático fortalece a interpretação do objetivo específico 3: os efeitos do ENSO sobre o desempenho do agronegócio agregado não devem ser compreendidos como uma relação direta e uniforme, mas como o resultado de mecanismos climáticos regionalmente diferenciados, que se combinam com estrutura produtiva, dinâmica de preços, integração a mercados e características das empresas que compõem o índice.

5.4 Análise assessoria: síntese do clima via PCA e desempenho do Arranjo Analítico 3

Como extensão metodológica e teste de solidez interpretativa, estimou-se um arranjo analítico alternativo (Arranjo Analítico 3) em que as variáveis climáticas regionais (precipitação) são sintetizadas por Análise de Componentes Principais (PCA), utilizando o primeiro componente (PC1) como fator climático agregado. A lógica dessa abordagem é reduzir dimensionalidade e colinearidade, preservando parte substancial da variação conjunta do clima.

5.4.1 Variância explicada e estrutura do PC1

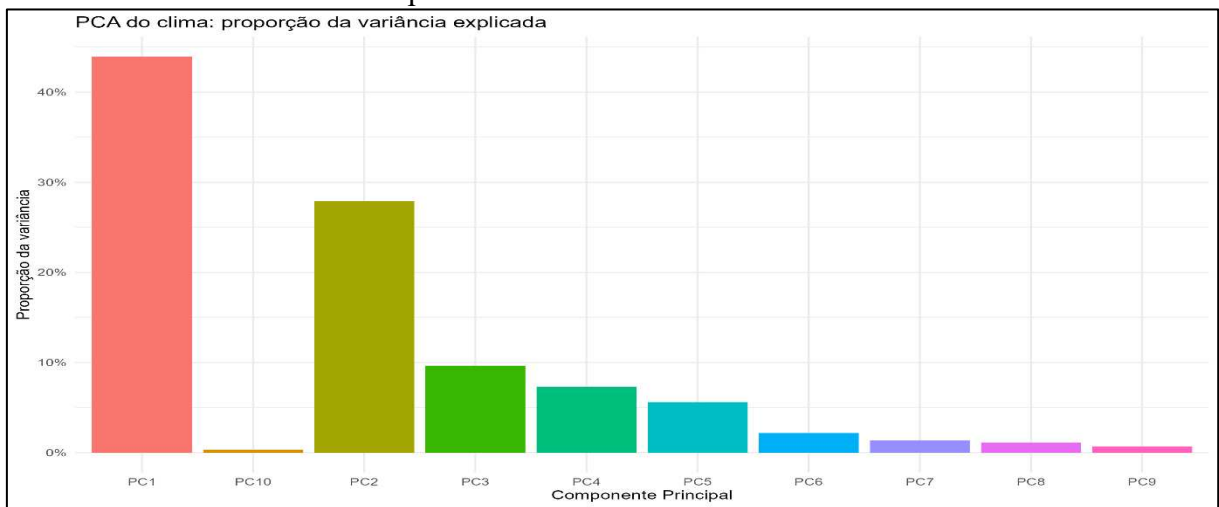
Como estratégia complementar de análise de teste de robusteza da modelagem econométrica, foi realizada uma Análise de Componentes Principais (*Principal Component Analysis* – PCA) aplicada ao conjunto de variáveis climáticas regionais utilizadas no estudo. A aplicação da PCA tem como sintetizar a informação contida em um conjunto de variáveis potencialmente correlacionadas, neste caso, as séries de precipitação média anual das macrorregiões brasileiras, em um número reduzido de componentes não correlacionados, preservando a maior parcela da variância total dos dados.

No contexto desta Dissertação, a PCA foi utilizada como mecanismo de redução de dimensionamento do sistema climático regional, condensando-se as distintas séries de precipitação em um fator climático agregado. A motivação econométrica dessa abordagem reside em dois aspectos principais. Primeiro, a correlação entre variáveis climáticas regionais é passível de conduzir problemas de colinearidade em modelos econométricos. Segundo, a formulação de um índice climático sintético conduz a se avaliar se existe uma componente

comum do regime pluviométrico nacional, capaz de afetar o desempenho agregado do agronegócio brasileiro.

O Gráfico 15 contém a distribuição da variância explicada pelos componentes principais extraídos da matriz de variáveis climáticas. Observa-se que o primeiro componente principal (PC1) concentra aproximadamente 43,9% da variabilidade total do sistema climático, enquanto o segundo componente (PC2) responde por cerca de 27,9%. Em conjunto, os dois primeiros componentes explicam aproximadamente 71,9% da variância total das variáveis analisadas, indicando uma dimensão comum relevante na dinâmica das precipitações regionais.

Gráfico 15 – PCA: variância explicada.



Fonte: Elaborado pelo autor.

A decomposição foi realizada com suporte na matriz padronizada das variáveis climáticas regionais, de modo que cada série contribua proporcionalmente para a análise, independentemente de diferenças de escala ou variabilidade. A técnica produz um conjunto de componentes principais ordenados de acordo com a parcela de variância total explicada por parte de cada um deles.

Os resultados da decomposição indicam que o primeiro componente principal (PC1) explica 43,948% da variância total do sistema climático, enquanto o segundo componente principal (PC2) responde por 27,914% da variância, totalizando 71,862% da variabilidade conjunta quando considerados os dois primeiros componentes.

Esse resultado sugere que existe uma componente comum relevante no comportamento das precipitações regionais, mas também indica a segunda dimensão climática importante, possivelmente associada às diferenças estruturais entre os regimes pluviométricos das macrorregiões brasileiras. A Tabela 3 demonstra a decomposição completa da variância explicada pelos componentes principais.

Tabela 3 – PCA do clima: proporção da variância explicada

Componente	Proporção da variância	Proporção acumulada
PC1	0,43948	0,43948
PC2	0,27914	0,71862
PC3	0,09593	0,81455
PC4	0,07312	0,88768
PC5	0,05601	0,94368
PC6	0,02163	0,96531
PC7	0,01344	0,97875
PC8	0,01138	0,99014
PC9	0,00704	0,99717
PC10	0,00283	1,00000

Fonte: Elaborada pelo autor.

A distribuição da variância entre os componentes evidencia que o comportamento climático agregado no Brasil não há de ser reduzido a fator dominante único, ainda que o PC1 concentre uma parcela expressiva da variabilidade total. O segundo componente com peso relativamente elevado reforça a existência de heterogeneidades espaciais importantes no regime de precipitação, compatíveis com a diversidade climática observada entre as regiões brasileiras.

Enquanto o PC1 captura a dimensão mais geral do sistema climático, isto é, a tendência comum de variação da precipitação em distintas regiões, o PC2 tende a refletir contrastes regionais, nos quais determinadas regiões são passíveis de mostrar comportamentos pluviométricos distintos ou até mesmo opostos.

Para compreender a estrutura do primeiro componente principal, é necessário analisar os *loadings* associados a cada variável climática. Os *loadings* indicam o peso relativo de cada variável original na composição do componente principal e concedem oportunidade a interpretar economicamente o significado do fator extraído. A tabela 4 concentra os *loadings* do primeiro componente principal (PC1) para as variáveis de precipitação regional utilizadas na análise.

Tabela 4 – PCA do clima: *loadings* do primeiro componente principal (PC1)

Variável climática	Loading no PC1
Precipitação – Centro-oeste	0,47
Precipitação – Nordeste	0,45
Precipitação – Norte	0,42
Precipitação – Sudeste	0,44
Precipitação – Sul	0,39

Fonte: Elaborada pelo autor.

A estrutura dos *loadings* indica que o primeiro componente principal é formado por contribuições positivas de todas as variáveis de precipitação regional, sugerindo que o PC1

representa uma dimensão agregada do regime pluviométrico brasileiro. Em termos estatísticos, isso significa que anos nos quais distintas regiões do País exprimem níveis relativamente elevados de precipitação tendem a produzir valores mais altos do PC1, enquanto períodos de precipitação mais baixa em várias regiões, simultaneamente, geram valores menores desse componente.

Do ponto de vista econômico, essa estrutura deixa interpretar o PC1 como um fator climático agregado, capaz de sintetizar o comportamento geral das condições hídricas relevantes para o sistema agropecuário brasileiro. Como a produção agrícola depende intensivamente da disponibilidade de água e da regularidade das chuvas, variações nesse fator climático agregado afetam, simultaneamente, diversas cadeias produtivas, influenciando produtividade, custos de produção, riscos climáticos e expectativas de mercado.

O fato de o PC1, entretanto, explicar menos da metade da variância total do sistema climático indica que a dinâmica pluviométrica brasileira é marcada por vigorosa heterogeneidade regional. *In aliis verbis*, embora exista uma dimensão comum de variabilidade climática, parte significativa da dinâmica do clima permanece associada a padrões regionais específicos, habilitados a responder de maneira diferenciada aos choques climáticos globais associados ao fenômeno ENSO.

Essa característica é particularmente relevante para a interpretação dos resultados econométricos desta Dissertação. Caso o desempenho do agronegócio brasileiro seja influenciado por mecanismos climáticos regionalmente diferenciados, como efeitos distintos do El Niño sobre a precipitação no Nordeste, no Sul ou no Centro-Oeste, a utilização de único fator climático agregado é passível de reduzir a capacidade explicativa do modelo.

Em síntese, os resultados da PCA apontam que o clima expressa, simultaneamente, uma dimensão agregada comum e contrastes regionais relevantes, o que tem implicações diretas para a modelagem econométrica do impacto do ENSO sobre o desempenho do agronegócio. Essa evidência empírica reforça a interpretação de que os efeitos climáticos sobre o setor não são uniformes no Território Nacional, mas resultam da interação de padrões climáticos regionais, estrutura produtiva e características específicas das cadeias agroindustriais que compõem o índice IboAgro.

5.4.2 Resultados do Arranjo Analítico 3 e implicações

Com o objetivo de investigar se a variabilidade climática é sintetizável em único fator agregado, estimou-se o Arranjo Analítico 3, no qual as variáveis de precipitação regional foram condensadas por meio da técnica da Análise de Componentes Principais (*Principal*

Component Analysis – PCA). Nesse arranjo, utiliza-se o primeiro componente principal (PC1) como uma *proxy* para a variabilidade climática agregada, captando a maior parcela possível da variância conjunta das séries de precipitação consideradas no estudo. Assim, o modelo econométrico passa a explicar a variação logarítmica do índice IboAgro ($\Delta \ln(IboAgro)$) em função de dois fatores: a intensidade do fenômeno El Niño, representada pelo índice ONI, e o fator climático sintético Clima_PC1, que resume a dinâmica conjunta das precipitações regionais.

A adoção dessa estratégia metodológica transporta a se avaliar se a informação climática regional é propícia a ser adequadamente representada por fator latente único, reduzindo a dimensionalidade do sistema climático e aumentando a parcimônia do modelo econométrico. Os resultados da estimação desse arranjo analítico encontram-se na Tabela 5.

Tabela 5 – Estimação do Arranjo Analítico 3: impacto do ONI e do fator climático agregado (PC1) sobre a variação logarítmica do índice IboAgro (HAC/Newy-West).


Variável	Estimativa	Erro-padrão (HAC)	Estatística t	p-valor
(Intercepto)	0,00273	0,00827	0,3302	0,7425
ONI	-0,01644	0,01961	-0,8386	0,4054
Clima PC1	-0,00764	0,00594	-1,2863	0,2039

Diagnóstico do Arranjo Analítico 1: $n = 56$; $R^2 = 0,0277$; $R^2_{ajust.} = -0,0090$; $AIC = -71,0185$; $BIC = -62,9171$.

Fonte: Elaborada pelo autor.

O resultado indigita que, ao sintetizar o clima em único fator (PC1), o arranjo analítico perde capacidade explicativa e não detecta efeito estatisticamente significativo do ONI nem do componente climático. Esse desempenho inferior sugere que, embora exista uma componente comum do clima regional, a relação entre clima e desempenho agregado do agronegócio é estruturada por heterogeneidade espacial, isto é, por combinações regionais específicas que não são bem capturadas por única dimensão agregada.

Gráfico 16 – Resposta marginal prevista de $\Delta \ln(IboAgro)$ às variações do ONI (Arranjo Analítico 3 com clima sintetizado por PCA)



Fonte: Elaborado pelo autor.

Em termos de interpretação vinculada aos objetivos da pesquisa, esse resultado denota utilidade analítica, mesmo não constituindo o modelo principal da investigação. O Arranjo Analítico 3 consiste em uma especificação econométrica alternativa na qual são as variáveis climáticas regionais de precipitação sintetizadas por meio de Análise de Componentes Principais (PCA), utilizando-se o primeiro componente principal (PC1) como um fator climático agregado. Essa estratégia tem como finalidade reduzir a dimensionalidade do sistema climático e condensar a informação contida nas variáveis regionais em único indicador sintético.

Os resultados desse arranjo apontam que, ao substituir as variáveis climáticas regionais por fator agregado único, o modelo perde capacidade explicativa e não identifica efeitos estatisticamente significativos das variáveis climáticas sobre a dinâmica do índice analisado. Esse resultado, longe de ser somente um exercício metodológico, contribui para reforçar uma conclusão relevante da pesquisa: o objetivo específico de investigar a sensibilidade regional dos efeitos climáticos sobre o agronegócio brasileiro não deve ser reduzido a único fator climático agregado.

In aliis verbis, a evidência empírica sugere que a transmissão dos choques climáticos associados ao fenômeno ENSO ocorre por mecanismos regionalmente diferenciados, refletindo a diversidade de regimes pluviométricos e de estruturas produtivas no Território Brasileiro. Assim, a tentativa de “colapsar” essa heterogeneidade somente numa dimensão climática, como ocorre no Arranjo Analítico 3, tende a obscurecer parte relevante da dinâmica que conecta variabilidade climática e desempenho econômico do agronegócio.

5.5 Síntese integrada dos Arranjos Analíticos e comparação de desempenho

Para sistematizar os resultados e consolidar a discussão, a Tabela 6 compara os diagnósticos globais dos três arranjos analíticos.

Tabela 6 – Comparação de ajuste e critérios de informação (Arranjos Analíticos 1, 2 e 3).

Arranjo Analítico	n	R^2	$R^2_{ajust.}$	AIC	BIC
1	56	0,4969	0,3565	-87,9163	-59,5613
2	56	0,5317	0,4010	-91,9335	-63,5786
3	56	0,0277	-0,0090	-71,0185	-62,9171

Fonte: Elaborada pelo autor.

A comparação evidencia que o Arranjo Analítica 2 expressa o melhor desempenho global entre os arranjos estimados, tanto em R^2 ajustado quando em critérios de informação, além de fornecer um resultado interpretativamente robusto: a penalização do desempenho do agronegócio agregado está concentrada no componente ONI_pos, associado a eventos de El

Niño. O Arranjo Analítico 1 também sustenta a relação negativa contemporânea entre ONI e retorno do índice, preservando a dimensão dinâmica e o detalhamento regional da precipitação. Já o Arranjo Analítico 3, ao reduzir a dimensionalidade climática, perde precisão explicativa, sugerindo que a heterogeneidade regional é parte constitutiva do mecanismo de transmissão do ENSO.

6 CONSIDERAÇÕES FINAIS

O ensaio que se termina de relatar e sustentar teve como objetivo geral analisar a relação entre a variabilidade climática associada ao fenômeno El Niño e o desempenho econômico-financeiro do agronegócio brasileiro, com arrimo na elaboração de um índice sintético representativo do setor e da aplicação de um conjunto articulado de métodos econométricos. A pesquisa foi estruturada de maneira a conduzir a uma leitura integrada entre mercado financeiro setorial e o clima, respeitando tanto os fundamentos teóricos quanto as especificidades empíricas do agronegócio brasileiro no decurso do período analisado.

Em atendimento ao primeiro objetivo específico, que consistiu na constituição de um índice representativo do desempenho do agronegócio brasileiro, denominado IboAgro, os resultados obtidos demonstram que a adaptação da metodologia do Ibovespa foi adequada e estatisticamente consistente para sintetizar o comportamento agregado das empresas do setor listadas na bolsa de valores brasileira. O índice apontou elevada sensibilidade às oscilações do mercado e coerência temporal com eventos econômicos e climáticos relevantes, evidenciando sua capacidade de capturar variações conjunturais e estruturais do agronegócio. A análise descritiva e gráfica realizada no Capítulo 5 mostrou que o IboAgro responde sistematicamente a choques externos, validando sua utilização como variável central nos modelos econométricos estimados.

No que se refere ao segundo objetivo específico, tendido à investigação da relação entre o fenômeno El Niño, mensurado pelo *Oceanic Niño Index* (ONI), e o desempenho do IboAgro, os resultados econométricos apontaram para a existência de uma relação estatisticamente significativa entre as variáveis climáticas e o desempenho do setor. As estimações indicaram que choques positivos no ONI produzem efeitos relevantes sobre a variação do IboAgro, com coeficientes estatisticamente significativos aos níveis convencionais de significância estatística, conforme discutido no Capítulo 5. Esse resultado reforça a hipótese de que eventos climáticos extremos não afetam apenas a produção física agropecuária, mas também se refletem nas expectativas, no comportamento dos investidores e na precificação dos ativos vinculados ao agronegócio.

O terceiro objetivo específico, direcionado à análise da dinâmica temporal dos impactos do fenômeno El Niño, foi alcançado por meio da aplicação de modelos VAR, das funções impulso-resposta (FIR) e da decomposição da variância do erro de previsão (DVEP). As FIRs indicaram que variações associadas ao El Niño provocam efeitos persistentes sobre o desempenho do IboAgro, os quais não se limitam ao período inicial do choque, estendendo-se

ao extenso de vários períodos subsequentes, o que explica a dificuldade em visualizar os efeitos graficamente. De modo complementar, os resultados da Decomposição da Variância do Erro de Previsão (DVEP) mostraram que uma parcela relevante da incerteza associada às previsões do IboAgro é atribuível às variações climáticas observadas, sobretudo nos horizontes de médio prazo, reforçando a compreensão de que o clima exerce papel estrutural na dinâmica econômica do agronegócio brasileiro.

De jeito complementar, a incorporação das variáveis de precipitação regional deu ensejo a se aprofundar a análise, ao evidenciar-se que os impactos climáticos não são homogêneos no espaço. Os resultados expressos no Capítulo 5 demonstraram que a precipitação exerce efeitos diferenciados sobre o desempenho do setor, a depender da região considerada, reforçando a importância de uma abordagem regionalizada na análise da relação entre clima e agronegócio. Essa evidência é particularmente relevante em um país imenso como o Brasil, assinalado por elevada heterogeneidade climática e produtiva.

Em termos analíticos e metodológicos, os resultados obtidos no experimento indicam que a integração entre indicadores financeiros, variáveis climáticas e modelos econométricos dinâmicos constitui um caminho promissor para a compreensão dos efeitos do clima sobre o desempenho do agronegócio. O modelo proposto mostrou-se capaz de capturar relações relevantes e estatisticamente significativas e estáveis, oferecendo evidências empíricas consistentes de que choques climáticos associados ao El Niño afetam o comportamento agregado das empresas do setor.

Ainda assim, é fundamental reconhecer que o modelo desenvolvido neste estudo não esgota as possibilidades analíticas sobre o tema. A opção metodológica adotada privilegiou um modelo relativamente parcimonioso, com o objetivo de reduzir problemas de multicolinearidade, facilitar a interpretação dos coeficientes estimados e preservar o foco analítico sobre a relação entre variabilidade climática e desempenho do agronegócio. Nesse sentido, a seleção das variáveis tencionou equilibrar simplicidade e capacidade explicativa.

Isso não significa, entretanto, que outros fatores potencialmente relevantes para o desempenho econômico-financeiro das empresas do agronegócio não sejam passíveis de exploração em investigações futuras. Variáveis de natureza institucional, logística, tecnológica, cambial e relacionadas à política agrícola estão habilitadas a desempenhar papel relevante na dinâmica do setor. Estudos posteriores terão condição de incorporar essas dimensões por meio de estratégias metodológicas apropriadas, como modelos ampliados, abordagens de seleção de variáveis ou estruturas econométricas alternativas, contribuindo para aprofundar a compreensão

dos mecanismos pelos quais o clima interage com outros determinantes estruturais do desempenho econômico do agronegócio.

Nesse sentido, esta experimentação há de ser compreendida como etapa inicial de um esforço de pesquisa contínuo, cujo objetivo final é a formulação de um modelo cada vez mais consistente e explicativo sobre os efeitos do clima nos resultados das empresas do agronegócio brasileiro. Estudos futuros, decerto, vão explorar extensões metodológicas, ampliar o conjunto de variáveis explicativas e aprofundar a análise regional, de modo a capturar com precisão a complexa interação do clima com o mercado e o desempenho econômico.

Ao responder sistemática e empiricamente fundamentada aos objetivos propostos, a Dissertação contribui para o avanço da literatura, quando evidencia que a variabilidade climática, em especial os episódios do fenômeno El Niño, constitui um determinante relevante do desempenho do agronegócio brasileiro. Ao mesmo tempo, abre espaço para investigações que aprofundem essa agenda de pesquisa, reforçando a importância de abordagens integradas entre economia, finanças e clima na análise do desenvolvimento do setor agropecuário.

REFERÊNCIAS

- AHMAD, Mohammad Reza; CHAUDHURI, Kausik; HASSAN, Ghullam Murtaza. **Impact of climate risk on equity premium: evidence from emerging and developed markets.** *Research in International Business and Finance*, [S.l.], v. 62, 2022.
- ASSAD, E. D. *et al.* **Climate change and agriculture: Impacts and adaptation options in Brazil.** *Agricultural Systems*, v. 196, 103293, 2022.
- B3 - BRASIL, BOLSA, BALCÃO. **Metodologia dos Índices da B3, 2024.** Disponível em: https://www.b3.com.br/data/files/32/67/A7/8C/16422410C4F3C6B088A80AC2/Methodologia_Indices.pdf. Acesso em: 10 jun. 2025.
- BALDWIN, E.; DIAS, M.; WINKLER, H. **Climate risk as systemic risk: Insights for financial and policy modeling.** *Climate Risk Management*, v. 41, p. 100555, 2023. DOI: 10.1016/j.crm.2023.100555
- CANE, Mark A. The evolution of El Niño, past and future. **Earth and Planetary Science Letters**, [S.l.], v. 230, n. 3–4, p. 227–240, 2005.
- DÉES, Stéphane; DI MAURO, Filippo; PESARAN, M. Hashem; SMITH, L. Vanessa. **Exploring the international linkages of the euro area: a global VAR analysis.** *Journal of Applied Econometrics*, Chichester, v. 22, n. 1, p. 1–38, 2007.
- DUFRENOT, Gilles. **Climate shocks, output volatility and financial stability: evidence from a panel GVAR.** Working Paper No. 309, CEPII – Centre d'Études Prospectives et d'Informations Internationales, Paris, 2023.
- FLORIDE, W.; KAMINSKI, J.; GUTIERREZ, L. **Modeling food price responses to climate anomalies using a Global VAR approach: evidence from Sub-Saharan Africa.** *Agricultural Economics*, [S.l.], v. 56, n. 2, p. 178 – 198, 2025.
- GUTIERREZ, L.; PIRAS, F.; ROGGERO, P. P. A global vector autoregression model for the analysis of wheat export prices. **American Journal of Agricultural Economics**, v. 97, n. 5, p. 1494 – 1511, 2014. DOI: 10.1093/ajae/aau103
- GUTIERREZ, Luciano; PIRAS, Francesco; ROGGERO, Pier Paolo. **A global vector autoregression model for the analysis of wheat export prices.** *American Journal of Agricultural Economics*, Cary, v. 97, n. 5, p. 1494–1511, 2014. DOI: 10.1093/ajae/aau103.
- INSTITUTO NACIONAL DE METEOROLOGIA - INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa.** Disponível em: <https://bdmep.inmet.gov.br/>. Acesso em: 10 jun. 2025.
- JOHANSEN, Søren. **Likelihood-based inference in cointegrated vector autoregressive models.** Oxford: Oxford University Press, 1995.
- LEMONS, José de Jesus Sousa. **Vulnerabilidades induzidas no Semiárido.** Fortaleza: Imprensa Univsersitária, 2020.
- KOOP, G.; PESARAN, M. H.; POTTER, S. M. Impulse response analysis in nonlinear multivariate models. **Journal of Econometrics**, Amsterdam, v. 74, n. 1, p. 119 – 147, 1996. DOI: 10.1016/0304-4076(95)01753-4

- KOOP, Gary; PESARAN, M. Hashem; POTTER, Simon M. Impulse response analysis in nonlinear multivariate models. **Journal of Econometrics**, Amsterdam, v. 74, n. 1, p. 119–147, 1996.
- LIMA, G. C.; ZILLI, J. A.; CUNHA, G. R. **Agricultural vulnerability to El Niño events in Brazil: An econometric analysis**. Environmental Research Communications, v. 5, n. 1, p. 015002, 2023.
- MARPAUNG, Bronson; SIREGAR, Hermanto; ANGGRAENI, Lukytwawati. **Analysis of El Niño impact and the price of food commodities on inflation**. Jurnal Ekonomi Indonesia, Bogor, v. 8, n. 1, p. 21 – 35, 2019.
- McPHADEN, M. J.; SANTOSO, A.; CAI, W. **Dynamics of El Niño-Southern Oscillation: Recent advances and future challenges**. Reviews of Geophysics, v. 58, n. 2, p. e2019RG000678, 2020.
- NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION – NOAA. **Historical El Niño/La Niña episodes (1950-present)**. Disponível em: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ENSOstuff/ONI_v5.php. Acesso em: 10 jun. 2025.
- PAINEL INTERGOVERNAMENTAL SOBRE MUDANÇAS CLIMÁTICAS - IPCC. **Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press, 2022.
- PESARAN, M. H.; SCHUERMANN, T.; WEINER, S. M. Modeling regional interdependencies using a global error-correcting macroeconomic model. **Journal of Business and Economic Statistics**, v. 22, n. 2, p. 129 – 162, 2004. Disponível em: <https://www.jstor.org/stable/1392105>
- PESARAN, M. H.; SHIN, Y.; SMITH, R. J. Structural analysis of vector error correction models with exogenous I(1) variables. **Journal of Econometrics**, v. 97, n. 2, p. 293 – 343, 2000. DOI: 10.1016/S0304-4076(99)00073-1
- PESARAN, M. Hashem; SCHUERMANN, Til; WEINER, Scott M. Modeling regional interdependencies using a global error-correcting macroeconomic model. **Journal of Business and Economic Statistics**, Alexandria, v. 22, n. 2, p. 129–162, 2004.
- PESARAN, M. Hashem; SHIN, Yongcheol; SMITH, Richard J. Structural analysis of vector error correction models with exogenous I(1) variables. **Journal of Econometrics**, Amsterdam, v. 97, n. 2, p. 293–343, 2000.
- PIERRE, Guillaume; GUTIERREZ, Luciano. **Agricultural grain markets in the COVID-19 crisis: insights from a GVAR model**. Working Paper, Department of Agricultural Sciences, University of Sassari, Italy, set. 2020.
- TORRES, R. R. *et al.* **Climate Risk Management Strategies for Agriculture in Brazil: Current Status and Future Perspectives**. Climatic Change, v. 165, 2021.
- UBILAVA, David. **El Niño, La Niña, and world coffee price dynamics**. Agricultural Economics, [S.l.], v. 47, n. 1, p. 109 – 119, 2016.
- WOOLDRIDGE, J. M. **Introductory Econometrics: A Modern Approach**. 7. ed. Boston: Cengage Learning, 2021.

APÊNDICE A – SÉRIES HISTÓRICAS AGREGADAS

ano	ONI	prec_CO	prec_NE	prec_N	prec_SE	prec_S	IboAgro
1968	0,14	1.564,43	1.139,93	2.023,78	1.106,34	1.274,68	980,97
1969	0,75	1.506,72	1.159,28	1.919,17	1.275,08	1.581,36	980,39
1970	-0,32	1.569,00	921,93	2.047,98	1.287,34	1.582,66	1055,53
1971	-0,94	1.557,06	1.129,89	2.016,58	1.390,05	1.568,33	944,13
1972	0,93	1.638,34	1.065,97	2.042,74	1.282,10	2.151,75	940,23
1973	-0,62	1.576,15	1.259,24	2.319,15	1.306,25	1.911,47	1011,94
1974	-0,89	1.556,68	1.605,92	2.257,73	1.296,36	1.514,90	807,25
1975	-1,05	1.457,30	1.287,40	2.183,12	1.282,57	1.687,14	970,74
1976	-0,05	1.587,34	994,70	2.069,37	1.406,52	1.695,73	1026,17
1977	0,51	1.485,97	1.336,06	2.118,05	1.289,90	1.647,94	882,19
1978	-0,10	1.635,92	1.188,29	2.088,21	1.242,88	1.302,78	951,72
1979	0,25	1.791,89	976,78	2.048,44	1.435,47	1.676,65	957,61
1980	0,25	1.687,10	1.039,89	2.099,49	1.307,44	1.687,94	1026,26
1981	-0,27	1.623,60	903,39	1.914,86	1.281,20	1.378,68	1028,27
1982	0,99	1.704,14	971,51	2.088,97	1.421,50	1.752,20	930,09
1983	0,48	1.878,12	767,73	1.750,17	1.863,55	2.146,70	887,98
1984	-0,51	1.399,98	1.189,54	2.190,28	1.115,06	1.722,13	1100,88
1985	-0,60	1.565,07	1.735,54	2.287,54	1.544,24	1.374,05	842,7
1986	0,25	1.411,47	1.374,31	2.065,74	1.154,30	1.649,21	975,74
1987	1,28	1.605,43	904,17	1.890,64	1.258,30	1.566,72	1008,39
1988	-0,81	1.561,18	1.251,11	2.080,69	1.202,98	1.388,03	1018,98
1989	-0,61	1.819,40	1.439,78	2.256,15	1.207,96	1.725,48	964,45
1990	0,32	1.473,14	823,94	2.101,23	1.001,85	2.058,06	1095,48
1991	0,65	1.694,72	974,12	2.026,09	1.311,61	1.399,56	1018,3
1992	0,63	1.905,68	994,04	1.848,10	1.566,78	1.769,74	864,54
1993	0,31	1.463,46	669,47	2.030,28	1.173,51	1.788,58	1106,48
1994	0,48	1.604,17	1.161,71	2.181,21	1.286,81	1.839,25	977,66
1995	-0,16	1.655,20	1.050,99	2.018,90	1.485,46	1.666,75	909,52
1996	-0,46	1.617,22	1.158,43	2.124,78	1.449,49	1.761,11	941,99
1997	1,15	1.680,83	967,53	2.022,94	1.395,83	1.909,17	920,1
1998	-0,06	1.591,05	835,15	1.985,32	1.259,63	2.055,04	1057,93
1999	-1,04	1.431,62	1.008,15	2.243,49	1.218,83	1.480,05	990,57
2000	-0,72	1.644,54	1.264,43	2.406,65	1.377,70	1.722,90	888,26
2001	-0,31	1.624,21	1.060,22	2.069,51	1.330,37	1.836,89	973,67
2002	0,63	1.514,89	1.109,33	2.143,00	1.262,52	1.810,69	998,49
2003	0,25	1.587,50	992,87	1.971,86	1.119,28	1.580,50	1039,71
2004	0,45	1.589,35	1.152,82	2.145,04	1.509,57	1.505,49	901,7

2005	0,04	1.679,41	1.051,12	2.101,19	1.594,76	1.736,03	939
2006	0,07	1.603,89	1.193,65	2.232,95	1.407,33	1.327,92	900,97
2007	-0,61	1.368,24	961,05	2.079,26	1.163,50	1.700,20	1098,65
2008	-0,78	1.660,74	1.247,19	2.231,97	1.363,48	1.706,23	927,07
2009	0,28	1.787,65	1.327,75	2.172,70	1.651,43	1.931,84	760,54
2010	-0,48	1.559,89	944,65	2.109,84	1.428,55	1.825,28	1001,87
2011	-0,86	1.656,12	1.238,75	2.156,91	1.448,67	1.664,80	954,49
2012	-0,15	1.631,23	697,77	1.912,12	1.414,94	1.563,40	1077,21
2013	-0,32	1.540,34	911,18	2.038,62	1.470,35	1.777,56	1008,07
2014	0,12	1.512,78	960,99	2.010,11	957,73	2.019,29	1175,01
2015	1,43	1.413,33	787,47	1.684,17	1.122,45	2.288,84	1080,47
2016	0,33	1.468,16	766,57	1.739,75	1.228,60	1.756,78	1115,26
2017	-0,20	1.446,12	1.004,34	1.883,18	1.119,37	1.935,29	1136,69
2018	0,01	1.533,35	933,87	2.038,65	1.342,31	1.691,62	981,39
2019	0,49	1.307,07	991,46	2.035,83	1.179,81	1.619,18	1009,53
2020	-0,36	1.377,22	1.168,30	1.881,94	1.369,58	1.361,87	1028,24
2021	-0,72	890,28	541,09	636,40	821,73	795,56	1297,29
2022	-0,94	915,80	710,91	811,07	1.042,43	1.047,71	1230,45
2023	0,81	1.063,93	804,70	1.016,59	1.093,43	1.450,75	1149,32
2024	0,35	1.126,19	830,13	1.117,58	1.087,43	1.315,33	1151,48

APÊNDICE B – SCRITP EM RStudio

```

> #####
> # SCRIPT ÚNICO (ATUALIZADO) – Brasil (todas as regiões)
> # Modelos dinâmicos para IboAgro com ONI + clima por REGIÃO:
> #   - Precipitação (prec_CO, prec_NE, prec_N, prec_SE, prec_S)
> #   - (Opcional) Temperatura (temp_CO, temp_NE, temp_N, temp_SE, temp_S)
> #
> # Modelos estimados (com erros HAC/Newey-west):
> # (M1)  $\Delta \ln(\text{IboAgro}) \sim \text{ONI} + \text{ONI}(-1) + \text{clima}$  (todas as regiões)
> # (M2)  $\Delta \ln(\text{IboAgro}) \sim \text{ONI}_{\text{pos}} + \text{ONI}_{\text{neg}} + \text{clima}$  (todas as regiões)
> # (M3) PCA do clima (PC1) + ONI [clima = precip + (opcional) temp]
> #
> # Gráficos (salvos em /graficos):
> # 01) IboAgro (nível)
> # 02)  $\Delta \ln(\text{IboAgro})$ 
> # 03) ONI (barras) colorido (El Niño/La Niña/Neutro)
> # 03b) IboAgro (linha) + ONI (barras) no mesmo gráfico (com eixo secundário)
> # 04) Precipitação por região (linhas)
> # 05) Temperatura por região (linhas) [se existir]
> # 06) Dispersão  $\Delta \ln(\text{IboAgro})$  vs ONI (colorida)
> # 07) Canal climático: ONI vs precipitação (5 gráficos, um por região)
> # 08) Canal climático: ONI vs temperatura (5 gráficos, um por região) [se existir]
> # 09) Coeficientes com IC95% (HAC) – M1/M2/M3
> # 10) PCA: variância explicada
> # 11) PCA: loadings PC1
> # 12) Predição marginal  $\Delta \ln(\text{IboAgro})$  vs ONI (M1)
> # 13) Predição marginal  $\Delta \ln(\text{IboAgro})$  vs ONI (M3)
> # 14) Resíduos vs tempo (M1)
> #
> # Saídas adicionais:
> # - CSVs de coeficientes HAC e diagnósticos
> # - CSV loadings do PC1
> #####
>
> # =====
> # 0) Pacotes
> # =====
> pkgs <- c("readxl","dplyr","tidyr","ggplot2","scales","lmtest","sandwich",
,"stringr")
> to_install <- pkgs[!pkgs %in% rownames(installed.packages())]
> if (length(to_install) > 0) install.packages(to_install)
> invisible(lapply(pkgs, library, character.only = TRUE))

Anexando pacote: 'dplyr'

Os seguintes objetos são mascarados por 'package:stats':
  filter, lag

Os seguintes objetos são mascarados por 'package:base':
  intersect, setdiff, setequal, union

Carregando pacotes exigidos: zoo

Anexando pacote: 'zoo'

Os seguintes objetos são mascarados por 'package:base':

```

```

as.Date, as.Date.numeric

Mensagens de aviso:
1: pacote 'readxl' foi compilado no R versão 4.4.3
2: pacote 'dplyr' foi compilado no R versão 4.4.3
3: pacote 'tidyr' foi compilado no R versão 4.4.3
4: pacote 'ggplot2' foi compilado no R versão 4.4.3
5: pacote 'scales' foi compilado no R versão 4.4.3
6: pacote 'lmtest' foi compilado no R versão 4.4.3
7: pacote 'zoo' foi compilado no R versão 4.4.3
8: pacote 'sandwich' foi compilado no R versão 4.4.3
>
> # =====
> # 1) Parâmetros do usuário
> # =====
> arquivo_excel <- "séries históricas agregadas.xlsx" # <- ajuste nome/cam
in角度
> aba <- 1 # <- nome/índice da a
ba
> lag_hac <- 3 # <- Newey-West
>
> # Classificação ENSO (ONI anual por limiar)
> limiar_el_niño <- 0.5
> limiar_la_nina <- -0.5
>
> # Se você tiver temperatura no arquivo, nomeie como:
> # temp_CO, temp_NE, temp_N, temp_SE, temp_S
> # Caso não exista, o script segue só com precipitação.
>
> # =====
> # 2) Leitura e checagens
> # =====
> df_raw <- read_excel(arquivo_excel, sheet = aba) %>% as.data.frame()
>
> # Colunas mínimas obrigatórias
> base_req <- c("ano", "IboAgro", "ONI")
> missing_base <- setdiff(base_req, names(df_raw))
> if (length(missing_base) > 0) {
+   stop(paste0("Faltam colunas obrigatórias: ", paste(missing_base, coll
apose = ", ")))
+ }
>
> # Detecta automaticamente colunas climáticas por região:
> # precip: prec_CO, prec_NE, prec_N, prec_SE, prec_S
> # temp : temp_CO, temp_NE, temp_N, temp_SE, temp_S (opcional)
> prec_cols <- names(df_raw)[stringr::str_detect(names(df_raw), "^prec_(CO|
NE|N|SE|S)$")]
> temp_cols <- names(df_raw)[stringr::str_detect(names(df_raw), "^temp_(CO|
NE|N|SE|S)$")]
>
> if (length(prec_cols) == 0) {
+   stop("Nenhuma coluna de precipitação encontrada. Esperado: prec_CO, p
rec_NE, prec_N, prec_SE, prec_S")
+ }
>
> # Define conjunto climático usado em modelos:
> clima_cols <- c(prec_cols, temp_cols) # inclui temperatura se existir
>
> cat("\nColunas de precipitação detectadas:\n"); print(prec_cols)

Colunas de precipitação detectadas:
[1] "prec_CO" "prec_NE" "prec_N" "prec_SE" "prec_S"
> cat("\nColunas de temperatura detectadas (opcional):\n"); print(temp_cols
)

Colunas de temperatura detectadas (opcional):
[1] "temp_CO" "temp_NE" "temp_N" "temp_SE" "temp_S"
> cat("\nColunas climáticas usadas nos modelos:\n"); print(clima_cols)

```

```

Colunas climáticas usadas nos modelos:
[1] "prec_CO" "prec_NE" "prec_N" "prec_SE" "prec_S" "temp_CO" "temp_NE"
"temp_N" "temp_SE"
[10] "temp_S"
>
> # =====
> # 3) Tipagem e ordenação
> # =====
> df <- df_raw %>%
+   mutate(
+     ano       = as.integer(ano),
+     IboAgro   = as.numeric(IboAgro),
+     ONI       = as.numeric(ONI)
+   ) %>%
+   arrange(ano)
>
> # Converte clima para numérico
> df[clima_cols] <- lapply(df[clima_cols], function(x) as.numeric(x))
>
> # =====
> # 4) Transformações
> # =====
> df <- df %>%
+   mutate(
+     ln_IboAgro = log(IboAgro),
+     dln_IboAgro = ln_IboAgro - lag(ln_IboAgro, 1),
+
+     ONI_l1     = lag(ONI, 1),
+
+     ONI_pos    = ifelse(ONI > 0, ONI, 0),
+     ONI_neg    = ifelse(ONI < 0, ONI, 0),
+
+     regime_ENSO = case_when(
+       ONI >= limiar_el_niño ~ "El Niño",
+       ONI <= limiar_la_niña ~ "La Niña",
+       TRUE ~ "Neutro"
+     ),
+     regime_ENSO = factor(regime_ENSO, levels = c("La Niña", "Neutro", "El Niño"))
+   ) %>%
+   filter(!is.na(dln_IboAgro))
>
> # =====
> # 5) Funções auxiliares
> # =====
> nw_test <- function(model, lag = 3) {
+   ct <- lmtest::coefest(model, vcov. = sandwich::NeweyWest(model, lag
= lag, prewhite = FALSE, adjust = TRUE))
+   data.frame(
+     term       = rownames(ct),
+     estimate   = ct[,1],
+     std.error  = ct[,2],
+     statistic  = ct[,3],
+     p.value    = ct[,4],
+     row.names  = NULL
+   )
+ }
>
> diag_basic <- function(model) {
+   data.frame(
+     n       = length(model$fitted.values),
+     r2      = summary(model)$r.squared,
+     r2_adj  = summary(model)$adj.r.squared,
+     aic     = AIC(model),
+     bic     = BIC(model),
+     stringsAsFactors = FALSE
+   )
+ }
>
> hac_coef_ci <- function(model, lag = 3, conf = 0.95) {

```

```

+   V <- sandwich::NeweyWest(model, lag = lag, prewhite = FALSE, adjust =
TRUE)
+   b <- coef(model)
+   se <- sqrt(diag(V))
+
+   alpha <- 1 - conf
+   crit <- qt(1 - alpha/2, df = df.residual(model))
+
+   data.frame(
+     term = names(b),
+     estimate = as.numeric(b),
+     std.error = as.numeric(se),
+     conf.low = as.numeric(b - crit * se),
+     conf.high = as.numeric(b + crit * se),
+     stringsAsFactors = FALSE
+   )
+ }
>
> predict_hac_ci <- function(model, newdata, lag = 3, conf = 0.95) {
+   V <- sandwich::NeweyWest(model, lag = lag, prewhite = FALSE, adjust =
TRUE)
+   X <- model.matrix(delete.response(terms(model)), data = newdata)
+   b <- coef(model)
+
+   fit <- as.numeric(X %>% b)
+   se_fit <- sqrt(diag(X %>% V %>% t(X)))
+
+   alpha <- 1 - conf
+   crit <- qt(1 - alpha/2, df = df.residual(model))
+
+   out <- newdata
+   out$fit <- fit
+   out$conf.low <- fit - crit * se_fit
+   out$conf.high <- fit + crit * se_fit
+   out
+ }
>
> # =====
> # 6) MODELOS (Brasil - todas as regiões)
> # =====
> rhs_m1 <- paste(c("ONI", "ONI_l1", clima_cols), collapse = " + ")
> rhs_m2 <- paste(c("ONI_pos", "ONI_neg", clima_cols), collapse = " + ")
>
> form_m1 <- as.formula(paste("dln_IboAgro ~", rhs_m1))
> form_m2 <- as.formula(paste("dln_IboAgro ~", rhs_m2))
>
> m1 <- lm(form_m1, data = df)
> m2 <- lm(form_m2, data = df)
>
> m1_hac <- nw_test(m1, lag = lag_hac)
> m2_hac <- nw_test(m2, lag = lag_hac)
> m1_diag <- diag_basic(m1)
> m2_diag <- diag_basic(m2)
>
> # PCA do clima (precip + temp, se existir)
> clima_mat <- df %>% select(all_of(clima_cols))
> pca_clima <- prcomp(clima_mat, center = TRUE, scale. = TRUE)
> df$clima_PC1 <- pca_clima$x[,1]
>
> m3 <- lm(dln_IboAgro ~ ONI + clima_PC1, data = df)
> m3_hac <- nw_test(m3, lag = lag_hac)
> m3_diag <- diag_basic(m3)
>
> # =====
> # 7) Exportações (CSVs)
> # =====
> write.csv(m1_hac, "resultado_modelo1_HAC.csv", row.names = FALSE)
> write.csv(m2_hac, "resultado_modelo2_HAC.csv", row.names = FALSE)
> write.csv(m3_hac, "resultado_modelo3_HAC.csv", row.names = FALSE)
>

```

```

> write.csv(m1_diag, "diagnostico_modelo1.csv", row.names = FALSE)
> write.csv(m2_diag, "diagnostico_modelo2.csv", row.names = FALSE)
> write.csv(m3_diag, "diagnostico_modelo3.csv", row.names = FALSE)
>
> loadings_pc1 <- data.frame(
+   variavel = rownames(pca_clima$rotation),
+   loading_PC1 = as.numeric(pca_clima$rotation[,1]),
+   row.names = NULL
+ )
> write.csv(loadings_pc1, "pca_loadings_PC1_clima.csv", row.names = FALSE)
>
> # =====
> # 8) Console (resumo)
> # =====
> cat("\n===== \nMODELO 1 (HAC) \n===== \n"); pr
int(m1_hac)

=====
MODELO 1 (HAC)
=====

```

	term	estimate	std.error	statistic	p.value
1	(Intercept)	-7.999837e-01	1.366974e+00	-0.5852222	0.561457054
2	ONI	-4.849416e-02	2.230529e-02	-2.1741103	0.035246959
3	ONI_l1	1.281111e-02	1.884162e-02	0.6799368	0.500188910
4	prec_CO	-1.142297e-04	1.784295e-04	-0.6401953	0.525442460
5	prec_NE	-2.719592e-04	1.168754e-04	-2.3269163	0.024747956
6	prec_N	1.298942e-04	1.130070e-04	1.1494346	0.256730094
7	prec_SE	-2.829348e-04	9.158675e-05	-3.0892551	0.003510688
8	prec_S	6.173559e-05	6.254471e-05	0.9870634	0.329133379
9	temp_CO	-1.764520e-02	9.423450e-02	-0.1872478	0.852347103
10	temp_NE	1.119369e-01	8.400115e-02	1.3325645	0.189693541
11	temp_N	-4.354721e-02	9.987678e-02	-0.4360094	0.665011155
12	temp_SE	-1.181621e-02	3.958359e-02	-0.2985128	0.766749624
13	temp_S	1.195036e-02	4.135440e-02	0.2889743	0.773989698

```

> cat("\nDiagnóstico:\n"); print(m1_diag)

Diagnóstico:

```

	n	r2	r2_adj	aic	bic
1	56	0.4968806	0.3564752	-87.91626	-59.56133

```

>
> cat("\n===== \nMODELO 2 (HAC) \n===== \n"); pr
int(m2_hac)

=====
MODELO 2 (HAC)
=====

```

	term	estimate	std.error	statistic	p.value
1	(Intercept)	-4.439183e-01	1.127563e+00	-0.39369699	0.6957502571
2	ONI_pos	-1.168810e-01	3.219826e-02	-3.63004126	0.0007486239
3	ONI_neg	4.061642e-02	6.385977e-02	0.63602525	0.5281309472
4	prec_CO	-1.448326e-04	1.626945e-04	-0.89021170	0.3783060094
5	prec_NE	-2.238582e-04	1.064747e-04	-2.10245392	0.0414056565
6	prec_N	7.383883e-05	1.016469e-04	0.72642498	0.4715142961
7	prec_SE	-2.685044e-04	7.922764e-05	-3.38902460	0.0015117530
8	prec_S	6.744447e-05	6.092315e-05	1.10704170	0.2744305540
9	temp_CO	1.221710e-02	8.959327e-02	0.13636185	0.8921716649
10	temp_NE	1.301794e-01	7.216068e-02	1.80402078	0.0782360400
11	temp_N	-8.353209e-02	9.892422e-02	-0.84440482	0.4031168390
12	temp_SE	-1.623051e-03	4.330028e-02	-0.03748362	0.9702728805
13	temp_S	-1.867482e-02	4.128375e-02	-0.45235279	0.6532887667

```

> cat("\nDiagnóstico:\n"); print(m2_diag)

Diagnóstico:

```

	n	r2	r2_adj	aic	bic
1	56	0.5317082	0.4010222	-91.93347	-63.57855

```

>
> cat("\n===== \nMODELO 3 (HAC) \n===== \n"); pr
int(m3_hac)

=====

```

```

MODELO 3 (HAC)
=====
      term      estimate  std.error  statistic  p.value
1 (Intercept)  0.002730419  0.008268711  0.3302110  0.7425423
2      ONI    -0.016442463  0.019606060  -0.8386419  0.4054369
3   clima_PC1 -0.007639969  0.005939437  -1.2863119  0.2039251
> cat("\nDiagnóstico:\n"); print(m3_diag)

Diagnóstico:
      n      r2      r2_adj      aic      bic
1  56 0.02765003 -0.009042423 -71.01851 -62.91711
>
> cat("\n=====PCA (clima) - Variância explicada\n=====
=====")

=====
PCA (clima) - Variância explicada
=====
> print(summary(pca_clima)$importance)
      PC6      PC7      PC8      PC9      PC10
Standard deviation  2.096375 1.670756 0.9794414 0.8551302 0.7483716 0.46
50811 0.3666282 0.3373762
Proportion of Variance 0.439480 0.279140 0.0959300 0.0731200 0.0560100 0.02
16300 0.0134400 0.0113800
Cumulative Proportion 0.439480 0.718620 0.8145500 0.8876800 0.9436800 0.96
53100 0.9787500 0.9901400
Standard deviation  0.2652401 0.1681607
Proportion of Variance 0.0070400 0.0028300
Cumulative Proportion 0.9971700 1.0000000
>
> # =====
> # 9) GRÁFICOS
> # =====
> dir.create("graficos", showWarnings = FALSE)
>
> save_plot <- function(p, filename, w = 10, h = 6, dpi = 300) {
+   ggsave(filename = file.path("graficos", filename), plot = p, width =
w, height = h, dpi = dpi)
+ }
>
> # Long precipitação
> prec_long <- df %>%
+   select(ano, all_of(prec_cols)) %>%
+   pivot_longer(cols = -ano, names_to = "variavel", values_to = "valor")
+ %>%
+   mutate(regiao = stringr::str_replace(variavel, "^prec_", ""),
+          regiao = recode(regiao, CO="Centro-Oeste", NE="Nordeste", N="N
orte", SE="Sudeste", S="Sul"))
>
> # Long temperatura (se existir)
> temp_long <- NULL
> if (length(temp_cols) > 0) {
+   temp_long <- df %>%
+   select(ano, all_of(temp_cols)) %>%
+   pivot_longer(cols = -ano, names_to = "variavel", values_to = "val
or") %>%
+   mutate(regiao = stringr::str_replace(variavel, "^temp_", ""),
+          regiao = recode(regiao, CO="Centro-Oeste", NE="Nordeste",
N="Norte", SE="Sudeste", S="Sul"))
+ }
>
> # 01) IboAgro (nível)
> p_ibo <- ggplot(df, aes(x = ano, y = IboAgro)) +
+   geom_line(linewidth = 1) +
+   geom_point(size = 2) +
+   labs(title = "Série do IboAgro (nível)", x = "Ano", y = "IboAgro") +
+   theme_minimal()
> save_plot(p_ibo, "01_serie_IboAgro_nivel.png")

```

```

>
> # 02) Δln(IboAgro)
> p_ret <- ggplot(df, aes(x = ano, y = dln_IboAgro)) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_line(linewidth = 1) +
+   geom_point(size = 2) +
+   labs(title = "Retorno do IboAgro: Δln(IboAgro)", x = "Ano", y = "Δln(
IboAgro)") +
+   theme_minimal()
> save_plot(p_ret, "02_retorno_dln_IboAgro.png")
>
> # 03) ONI colorido ENSO
> p_oni <- ggplot(df, aes(x = ano, y = ONI, fill = regime_ENSO)) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_hline(yintercept = c(limiar_la_nina, limiar_el_nino), linetype =
"dotted") +
+   geom_col(width = 0.85, alpha = 0.95) +
+   labs(title = "ONI (Oceanic Niño Index) por ano e regime ENSO", x = "A
no", y = "ONI", fill = "Classificação") +
+   scale_fill_manual(values = c("La Niña"="#2C7BB6","Neutro"="#BDBDBD","
El Niño"="#D7191C")) +
+   theme_minimal()
> save_plot(p_oni, "03_ONI_colunas_colorido_ENSO.png")
>
> # 03b) IboAgro (linha) + ONI (barras) no mesmo gráfico
> #   - ONI no eixo primário (barras)
> #   - IboAgro reescalado para a escala do ONI (linha), com eixo secundá
rio revertendo para IboAgro
> Ibo_min <- min(df$IboAgro, na.rm = TRUE)
> Ibo_max <- max(df$IboAgro, na.rm = TRUE)
> ONI_min <- min(df$ONI, na.rm = TRUE)
> ONI_max <- max(df$ONI, na.rm = TRUE)
>
> # Evita divisão por zero se IboAgro for constante (caso raro)
> if (isTRUE(all.equal(Ibo_min, Ibo_max))) {
+   df$IboAgro_on_oni_scale <- mean(df$ONI, na.rm = TRUE)
+ } else {
+   df$IboAgro_on_oni_scale <- (df$IboAgro - Ibo_min) / (Ibo_max - Ibo_mi
n) * (ONI_max - ONI_min) + ONI_min
+ }
>
> p_ibo_oni <- ggplot(df, aes(x = ano)) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_col(aes(y = ONI, fill = regime_ENSO), width = 0.85, alpha = 0.90
) +
+   geom_line(aes(y = IboAgro_on_oni_scale), linewidth = 1.1) +
+   geom_point(aes(y = IboAgro_on_oni_scale), size = 2) +
+   scale_y_continuous(
+     name = "ONI (barras)",
+     sec.axis = sec_axis(
+       trans = ~ (. - ONI_min) / (ONI_max - ONI_min) * (Ibo_max - Ib
o_min) + Ibo_min,
+       name = "IboAgro (linha)"
+     )
+   ) +
+   scale_fill_manual(values = c("La Niña"="#2C7BB6","Neutro"="#BDBDBD","
El Niño"="#D7191C")) +
+   labs(
+     title = "Séries históricas: IboAgro (linha) e ONI (barras)",
+     x = "Ano",
+     fill = "Regime ENSO"
+   ) +
+   theme_minimal()
Mensagem de aviso:
The `trans` argument of `sec_axis()` is deprecated as of ggplot2 3.5.0.
[i] Please use the `transform` argument instead.
This warning is displayed once every 8 hours.
Call `lifecycle::last_lifecycle_warnings()` to see where this warning was g
enerated.

```

```

> save_plot(p_ibo_oni, "03b_IboAgro_linha_ONI_barras.png", w = 12, h = 6)
>
> # 04) Precipitação por região
> p_prec <- ggplot(prec_long, aes(x = ano, y = valor, color = regioao)) +
+   geom_line(linewidth = 1) +
+   geom_point(size = 1.6) +
+   labs(title = "Precipitação média anual por região (Brasil)", x = "Ano",
+         y = "Precipitação", color = "Região") +
+   theme_minimal()
> save_plot(p_prec, "04_precipitacao_regioes.png", w = 12, h = 6)
>
> # 05) Temperatura por região (se existir)
> if (!is.null(temp_long)) {
+   p_temp <- ggplot(temp_long, aes(x = ano, y = valor, color = regioao))
+
+   geom_line(linewidth = 1) +
+   geom_point(size = 1.6) +
+   labs(title = "Temperatura média anual por região (Brasil)", x = "Ano",
+         y = "Temperatura", color = "Região") +
+   theme_minimal()
+   save_plot(p_temp, "05_temperatura_regioes.png", w = 12, h = 6)
+ }
>
> # 06) Δln(IboAgro) vs ONI (colorida por regime)
> p_scatter_oni <- ggplot(df, aes(x = ONI, y = dln_IboAgro, color = regime_ENSO)) +
+   geom_point(size = 2.5, alpha = 0.85) +
+   geom_smooth(method = "lm", se = TRUE) +
+   labs(title = "Δln(IboAgro) vs ONI (tendência linear)", x = "ONI", y = "Δln(IboAgro)",
+         color = "Regime") +
+   theme_minimal()
> save_plot(p_scatter_oni, "06_scatter_dlnIboAgro_vs_ONI.png")
`geom_smooth() ` using formula = 'y ~ x'
>
> # 07) Canal climático: ONI vs precipitação – um gráfico por região
> for (col in prec_cols) {
+   reg <- stringr::str_replace(col, "^prec_", "")
+   nome_reg <- dplyr::recode(reg, CO="Centro-Oeste", NE="Nordeste", N="Norte",
+                             SE="Sudeste", S="Sul")
+   p <- ggplot(df, aes(x = ONI, y = .data[[col]], color = regime_ENSO))
+
+   geom_point(size = 2.5, alpha = 0.85) +
+   geom_smooth(method = "lm", se = TRUE) +
+   labs(
+     title = paste0("Canal climático: ONI vs Precipitação (", nome_reg, ")"),
+     x = "ONI", y = col, color = "Regime"
+   ) +
+   theme_minimal()
+   save_plot(p, paste0("07_ONI_vs_", col, ".png"))
+ }
`geom_smooth() ` using formula = 'y ~ x'
`geom_smooth() ` using formula = 'y ~ x'
`geom_smooth() ` using formula = 'y ~ x'
`geom_smooth() ` using formula = 'y ~ x'
`geom_smooth() ` using formula = 'y ~ x'
>
> # 08) Canal climático: ONI vs temperatura – um gráfico por região (se existir)
> if (length(temp_cols) > 0) {
+   for (col in temp_cols) {
+     reg <- stringr::str_replace(col, "^temp_", "")
+     nome_reg <- dplyr::recode(reg, CO="Centro-Oeste", NE="Nordeste",
+                               N="Norte", SE="Sudeste", S="Sul")
+     p <- ggplot(df, aes(x = ONI, y = .data[[col]], color = regime_ENSO)) +
+
+     geom_point(size = 2.5, alpha = 0.85) +
+     geom_smooth(method = "lm", se = TRUE) +
+     labs(

```

```

+         title = paste0("Canal climático: ONI vs Temperatura (" , n
ome_reg, ")"),
+         x = "ONI", y = col, color = "Regime"
+       ) +
+       theme_minimal()
+     save_plot(p, paste0("08_ONI_vs_", col, ".png"))
+   }
+ }
+ geom_smooth() ` using formula = 'y ~ x'
+ geom_smooth() ` using formula = 'y ~ x'
+ geom_smooth() ` using formula = 'y ~ x'
+ geom_smooth() ` using formula = 'y ~ x'
+ geom_smooth() ` using formula = 'y ~ x'
>
> # 09) Coeficientes com IC95% (HAC) - M1/M2/M3
> c1 <- hac_coef_ci(m1, lag = lag_hac) %>% mutate(modelo = "Modelo 1")
> c2 <- hac_coef_ci(m2, lag = lag_hac) %>% mutate(modelo = "Modelo 2")
> c3 <- hac_coef_ci(m3, lag = lag_hac) %>% mutate(modelo = "Modelo 3")
>
> coef_all <- bind_rows(c1, c2, c3) %>% filter(term != "(Intercept)")
>
> p_coef <- ggplot(coef_all, aes(x = reorder(term, estimate), y = estimate,
color = modelo)) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_point(position = position_dodge(width = 0.6), size = 2.3) +
+   geom_errorbar(aes(ymin = conf.low, ymax = conf.high),
+                 position = position_dodge(width = 0.6),
+                 width = 0.25, linewidth = 0.8) +
+   coord_flip() +
+   labs(title = "Coeficientes estimados com IC 95% (HAC/Newey-West)", x
= "Variável", y = "Estimativa", color = "Modelo") +
+   theme_minimal()
> save_plot(p_coef, "09_coeficientes_HAC_IC95.png", w = 12, h = 7)
>
> # 10) PCA: variância explicada
> imp <- summary(pca_clima)$importance
> pve <- data.frame(
+   PC = colnames(imp),
+   prop = as.numeric(imp["Proportion of Variance", ])
+ )
>
> p_pca_var <- ggplot(pve, aes(x = PC, y = prop, fill = PC)) +
+   geom_col() +
+   scale_y_continuous(labels = scales::percent_format(accuracy = 1)) +
+   labs(title = "PCA do clima: proporção da variância explicada", x = "C
omponente Principal", y = "Proporção da variância") +
+   theme_minimal() +
+   theme(legend.position = "none")
> save_plot(p_pca_var, "10_PCA_variância_explicada.png")
>
> # 11) PCA: loadings PC1
> load_pc1 <- loadings_pc1 %>% arrange(loading_PC1)
>
> p_pca_load <- ggplot(load_pc1, aes(x = reorder(variavel, loading_PC1), y
= loading_PC1, fill = variavel)) +
+   geom_col() +
+   coord_flip() +
+   labs(title = "PCA do clima: loadings do 1º componente (PC1)", x = "Va
riável", y = "Loading (PC1)") +
+   theme_minimal() +
+   theme(legend.position = "none")
> save_plot(p_pca_load, "11_PCA_loadings_PC1.png", w = 10, h = 6)
>
> # 12) Predição marginal  $\Delta \ln(\text{IboAgro})$  vs ONI (Modelo 1)
> oni_grid <- seq(min(df$ONI, na.rm = TRUE), max(df$ONI, na.rm = TRUE), len
gth.out = 100)
>
> nd_m1 <- data.frame(ONI = oni_grid, ONI_l1 = mean(df$ONI_l1, na.rm = TRUE
))
> for (v in clima_cols) nd_m1[[v]] <- mean(df[[v]], na.rm = TRUE)

```

```

>
> pred_m1 <- predict_hac_ci(m1, nd_m1, lag = lag_hac)
>
> p_pred_m1 <- ggplot(pred_m1, aes(x = ONI, y = fit)) +
+   geom_ribbon(aes(ymin = conf.low, ymax = conf.high), alpha = 0.25) +
+   geom_line(linewidth = 1) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   labs(title = "Resposta marginal prevista: Δln(IboAgro) vs ONI (Modelo
1, HAC)", x = "ONI", y = "Δln(IboAgro) previsto") +
+   theme_minimal()
> save_plot(p_pred_m1, "12_predicao_marginal_ONI_Modelo1.png")
>
> # 13) Predição marginal Δln(IboAgro) vs ONI (Modelo 3)
> nd_m3 <- data.frame(ONI = oni_grid, clima_PC1 = mean(df$clima_PC1, na.rm
= TRUE))
> pred_m3 <- predict_hac_ci(m3, nd_m3, lag = lag_hac)
>
> p_pred_m3 <- ggplot(pred_m3, aes(x = ONI, y = fit)) +
+   geom_ribbon(aes(ymin = conf.low, ymax = conf.high), alpha = 0.25) +
+   geom_line(linewidth = 1) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   labs(title = "Resposta marginal prevista: Δln(IboAgro) vs ONI (Modelo
3, HAC)", x = "ONI", y = "Δln(IboAgro) previsto") +
+   theme_minimal()
> save_plot(p_pred_m3, "13_predicao_marginal_ONI_Modelo3.png")
>
> # 14) Resíduos vs tempo (Modelo 1)
> res_m1 <- data.frame(ano = df$ano, resid = resid(m1))
> p_resid <- ggplot(res_m1, aes(x = ano, y = resid)) +
+   geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_line(linewidth = 1) +
+   geom_point(size = 2) +
+   labs(title = "Resíduos ao longo do tempo (Modelo 1)", x = "Ano", y =
"Resíduo") +
+   theme_minimal()
> save_plot(p_resid, "14_residuos_Modelo1_tempo.png")
>
> # =====
> # 10) Encerramento
> # =====
> cat("\n=====
\nConcluído.\n=====
\n")

=====
Concluído.
=====
> cat("Modelos (HAC) exportados:\n")
Modelos (HAC) exportados:
> cat("- resultado_modelo1_HAC.csv | resultado_modelo2_HAC.csv | resultado_
modelo3_HAC.csv\n")
- resultado_modelo1_HAC.csv | resultado_modelo2_HAC.csv | resultado_modelo3
_HAC.csv
> cat("Diagnósticos exportados:\n")
Diagnósticos exportados:
> cat("- diagnostico_modelo1.csv | diagnostico_modelo2.csv | diagnostico_mo
delo3.csv\n")
- diagnostico_modelo1.csv | diagnostico_modelo2.csv | diagnostico_modelo3.c
sv
> cat("PCA loadings exportados:\n")
PCA loadings exportados:
> cat("- pca_loadings_PC1_clima.csv\n")
- pca_loadings_PC1_clima.csv
> cat("\nGráficos gerados em: graficos/\n")

Gráficos gerados em: graficos/
> cat("- 01_serie_IboAgro_nivel.png\n")
- 01_serie_IboAgro_nivel.png
> cat("- 02_retorno_dln_IboAgro.png\n")
- 02_retorno_dln_IboAgro.png
> cat("- 03_ONI_colunas_colorido_ENSO.png\n")
- 03_ONI_colunas_colorido_ENSO.png

```

```
> cat("- 03b_IboAgro_linha_ONI_barras.png\n")
- 03b_IboAgro_linha_ONI_barras.png
> cat("- 04_precipitacao_regioes.png\n")
- 04_precipitacao_regioes.png
> if (length(temp_cols) > 0) cat("- 05_temperatura_regioes.png\n")
- 05_temperatura_regioes.png
> cat("- 06_scatter_dlnIboAgro_vs_ONI.png\n")
- 06_scatter_dlnIboAgro_vs_ONI.png
> cat("- 07_ONI_vs_prec_*.png (um por região)\n")
- 07_ONI_vs_prec_*.png (um por região)
> if (length(temp_cols) > 0) cat("- 08_ONI_vs_temp_*.png (um por região)\n"
)
- 08_ONI_vs_temp_*.png (um por região)
> cat("- 09_coeficientes_HAC_IC95.png\n")
- 09_coeficientes_HAC_IC95.png
> cat("- 10_PCA_variancia_explicada.png\n")
- 10_PCA_variancia_explicada.png
> cat("- 11_PCA_loadings_PC1.png\n")
- 11_PCA_loadings_PC1.png
> cat("- 12_predicao_marginal_ONI_Modelo1.png\n")
- 12_predicao_marginal_ONI_Modelo1.png
> cat("- 13_predicao_marginal_ONI_Modelo3.png\n")
- 13_predicao_marginal_ONI_Modelo3.png
> cat("- 14_residuos_Modelo1_tempo.png\n")
- 14_residuos_Modelo1_tempo.png
> cat("\nAjuste apenas: arquivo_excel e aba no topo do script.\n")
```