

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA**

HYGOR LUCAS XAVIER DA CUNHA

**IMPACTOS DAS MUDANÇAS CLIMÁTICAS E DO FENÔMENO EL NIÑO -
OSCILAÇÃO SUL NA PRODUÇÃO DE SOJA NO BRASIL**

JUIZ DE FORA – MG

2025

HYGOR LUCAS XAVIER DA CUNHA

**IMPACTOS DAS MUDANÇAS CLIMÁTICAS E DO FENÔMENO EL NIÑO -
OSCILAÇÃO SUL NA PRODUÇÃO DE SOJA NO BRASIL**

Monografia apresentada ao curso de Ciências
Econômicas da Universidade Federal de Juiz de
Fora, como requisito à obtenção do título de
bacharel em Ciências Econômicas.

Orientador: Prof. Weslem Rodrigues Faria

Coorientador: Jefferson Douglas da Silva Pereira

JUIZ DE FORA - MG

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Xavier da Cunha, Hygor Lucas.
IMPACTOS DAS MUDANÇAS CLIMÁTICAS E DO FENÔMENO EL NIÑO - OSCILAÇÃO SUL NA PRODUÇÃO DE SOJA NO BRASIL / Hygor Lucas Xavier da Cunha. -- 2025.
70 p. : il.

Orientador: Weslem Rodrigues Faria
Coorientador: Jefferson Douglas da Silva Pereira
Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2025.

1. Soja. 2. Produção. 3. Mudanças climáticas. 4. El Niño. 5. La Niña. I. Rodrigues Faria, Weslem, orient. II. da Silva Pereira, Jefferson Douglas, coorient. III. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 18/08/2025, a Banca Examinadora, composta pelos professores

- 1 – Weslem Rodrigues Faria - orientador;
- 2 – Jefferson Doglas da Silva Pereira - coorientador; e
- 3 – Admir Antonio Betarelli Junior,

reuniu-se para avaliar a monografia do acadêmico Hygor Lucas Xavier da Cunha, intitulada: Impactos das mudanças climáticas e do fenômeno El Nino - Oscilação Sul na produção de soja no Brasil.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu APROVAR a referida monografia

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Weslem Rodrigues Faria, Professor(a)**, em 22/08/2025, às 14:06, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Admir Antonio Betarelli Junior, Professor(a)**, em 22/08/2025, às 14:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Jefferson Doglas da Silva Pereira, Usuário Externo**, em 22/08/2025, às 14:53, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2571974** e o código CRC **AA75F454**.

Referência: Processo nº 23071.936757/2025-61

SEI nº 2571974

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Milton e Neusa, à minha irmã e sobrinha, Hayssa e Maria Clara, e à minha namorada Ruth por todo apoio e confiança depositada ao longo do processo de formação. Sem vocês, minha trajetória acadêmica e pessoal não faria sentido. Não tenho palavras para demonstrar a gratidão por estar cercado de pessoas que acreditam em mim e me amam e, por isso, dedico este trabalho a vocês.

Em seguida, registro meu agradecimento ao professor Weslem, por todo acompanhamento ao durante a graduação. Seus ensinamentos e conversas foram fundamentais para meu amadurecimento acadêmico e certamente me guiaram e motivaram na execução deste trabalho. Não posso deixar de agradecer também ao Jefferson, cujo zelo e persistência, mesmo nos momentos mais difíceis, me mostraram como é lidar com os desafios encontrados com dedicação e cuidado. Serei eternamente grato por todo acolhimento e confiança depositado em mim.

Estendo meus agradecimentos ao professor Admir, por aceitar o convite de compor a banca avaliadora, pela disponibilidade em analisar este trabalho e pelas valiosas contribuições que enriqueceram a pesquisa.

Por fim, agradeço aos amigos que conquistei ao longo da graduação, com quem compartilhei experiências que levarei para toda a vida e com a certeza de que continuaremos nos encontrando em diferentes momentos de nossa trajetória. Aos amigos de escola e de fora dela, deixo meu sincero agradecimento pela presença e pelo apoio nesta caminhada.

RESUMO

Este estudo investiga os impactos das mudanças climáticas na produção da soja no Brasil entre 2010 e 2023, com ênfase nos efeitos dos fenômenos *El Niño* e *La Niña* (ENOS). Utilizando uma função de produção Cobb-Douglas modificada e um modelo econométrico com efeitos fixos, o trabalho integra dados georreferenciados e variáveis climáticas para estimar o valor de produção da soja. Posteriormente, simula-se o impacto de aumentos na temperatura média em 0,5 °C, 1,0 °C e 1,5 °C sobre a produção. Os resultados indicam que um aumento médio de 1 °C durante a fase de crescimento da soja pode reduzir sua produção em até 74,36% em anos de *El Niño* e 70,6% em anos de *La Niña*. Os achados ressaltam a necessidade de políticas públicas que mitiguem os efeitos do aquecimento global e promovam estratégias adaptativas para a agricultura.

Palavras-chave: Soja, Produção, Mudanças climáticas, El Niño, La Niña.

ABSTRACT

This study investigates the impacts of climate change on soybean production in Brazil between 2010 and 2023, with a particular focus on the effects of *El Niño* and *La Niña* (ENSO). A modified Cobb-Douglas production function combined with a fixed-effects econometric model was employed, integrating georeferenced data and climatic variables to estimate soybean production value. Additionally, scenario simulations assessed the effects of temperature increases of 0.5 °C, 1.0 °C, and 1.5 °C on production. Results reveal that a 1 °C rise in average temperature during the soybean growth phase could reduce output by up to 74.36% in *El Niño* years and 70.6% in *La Niña* years. These findings highlight the urgent need for public policies to mitigate the effects of global warming and to foster adaptive strategies for agriculture.

Keywords: Soybean, Production, Climate Change, El Niño, La Niña.

LISTA DE GRÁFICOS

Gráfico 1 – Produção total de soja (em toneladas) no Brasil entre as safras de 2010/11 até 2023/24.....20

Gráfico 2 - Área plantada de soja (em milhões de hectares) no Brasil entre as safras de 2010/11 até 2023/24.....20

Gráfico 3 – Produtividade média (em kg/ha) da cultura de soja no Brasil entre as safras de 2010/11 até 2023/24.....21

LISTA DE FIGURAS

- Figura 1 – Decréscimos de rendimento da soja sob diferentes níveis de sombreamento (0% sombreamento = 100% rendimento de grãos).....17**
- Figura 2 – Fotoperíodo (em horas) ao longo do ano em função da latitude do local.....18**
- Figura 3 - Mapas de produtividade média (em R\$ / hectare) para os municípios produtores de soja no Brasil nos anos destacados.....51**
- Figura 4 - Mapas de temperatura média (em °C) para os municípios produtores de soja no Brasil nos anos destacados.....52**
- Figura 5 - Mapas de precipitação média (em mm) para os municípios produtores de soja no Brasil nos anos destacados.....53**

LISTA DE TABELAS

TABELA 1- Participação da soja no Valor Bruto da Produção (em bilhões de reais) do Brasil entre 2010 e 2021.....	22
TABELA 2 - Estatísticas descritivas.....	48
TABELA 3 - Estimativas da função de produção ampliada para o modelo de Efeitos Fixos.....	55
TABELA 4 - Variação (%) na produção de soja sob cenários de aumento de temperatura e precipitação.....	60

LISTA DE ABREVIATURAS E SIGLAS

ABIOVE – Associação Brasileira das Indústrias de Óleos Vegetais

CEPEA – Centro de Estudos Avançados em Economia Aplicada

CONAB – Companhia Nacional de Abastecimento

CPC – Climate Prediction Center

EA – Efeitos Aleatórios

EF – Efeitos Fixos

EGC – Equilíbrio Geral Computável

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária

ENOS – El Niño–Oscilação Sul

FAO - Food and Agriculture Organization

FGV – Fundação Getúlio Vargas

IBGE – Instituto Brasileiro de Geografia e Estatística

INMET – Instituto Nacional de Meteorologia

IPCC – Painel Intergovernamental sobre Mudanças Climáticas

MATOPIBA – Maranhão, Tocantins, Piauí e Bahia

NA – Não Aplicável

NOAA – National Oceanic and Atmospheric Administration

PAM – Pesquisa Agrícola Municipal

PIB – Produto Interno Bruto

STICS – Simulateur multi-Inputs pour la Croissance des Cultures et des Sols

VBP – Valor Bruto da Produção

SUMÁRIO

1 INTRODUÇÃO	13
2 DESEMPENHO ECOFISIOLÓGICO E CARACTERIZAÇÃO DA PRODUÇÃO DE SOJA.....	16
2.1 ECOFISIOLOGIA DA SOJA.....	16
2.2 CARACTERIZAÇÃO DA PRODUÇÃO DE SOJA NO BRASIL	19
3 REVISÃO DA LITERATURA	23
3.1 MUDANÇAS CLIMÁTICAS E PRODUÇÃO AGRÍCOLA.....	24
3.2 PRODUÇÃO DA SOJA E EVENTOS CLIMÁTICOS ASSOCIADOS AO ENOS ...	26
4 METODOLOGIA.....	29
4.1 MODELO TEÓRICO	29
4.2 MODELO EMPÍRICO	32
4.3 DADOS EM PAINEL.....	34
4.3.1 Modelos de dados em painel	34
4.3.2 Estimadores de dados em painel.....	38
4.4 BASE DOS DADOS E VARIÁVEIS.....	40
5 RESULTADOS E DISCUSSÕES	45
5.1 ESTATÍSTICAS DESCRITIVAS	45
5.2 RESULTADOS DA ESTIMAÇÃO DA FUNÇÃO DE PRODUÇÃO.....	54
5.3 EFEITOS DA TEMPERATURA E PRECIPITAÇÃO SOBRE A PRODUÇÃO DE SOJA.....	58
5.4 COMPARAÇÃO ENTRE VARIAÇÃO DE TEMPERATURA NA PRODUÇÃO DE SOJA EM DIFERENTES PERÍODOS	60
6 CONSIDERAÇÕES FINAIS.....	62
REFERÊNCIAS BIBLIOGRÁFICAS	64
APÊNDICE.....	70

1 INTRODUÇÃO

De acordo com os dados da FAO (2025), em 2024 o Brasil foi o maior produtor e exportador mundial de soja, posição alcançada graças à expressiva expansão da produção e área plantada na última década (CONAB, 2025). Na safra 2024/25, o país produziu cerca de 169 milhões de toneladas, o que representa 40,3% da produção global, com destaque para o estado do Mato Grosso, responsável por 50 milhões de toneladas - aproximadamente 30% da produção nacional e 12% da mundial (EMBRAPA, 2025). Segundo dados da CONAB (2025), entre as safras de 2010/11 e 2023/24, a produção nacional passou de 75,3 para 147,7 milhões de toneladas, também registrando no mesmo período um salto de 24,2 para 46,1 milhões de hectares plantados. Durante o período, o valor da produtividade apresentou oscilações positivas e negativas, partindo de 3115 quilogramas por hectare para 3201 quilogramas por hectare.

A soja é uma cultura altamente dependente das condições ambientais, sendo influenciada por fatores como temperatura, precipitação, radiação solar e disponibilidade hídrica. A compreensão das exigências climáticas e das interações entre o sistema solo-planta-atmosfera é essencial para mitigar os riscos produtivos, especialmente em fases críticas como a floração e o enchimento dos grãos (Farias et al., 2007; Neumaier et al., 2020).

As mudanças climáticas vêm alterando a dinâmica da produção agrícola, principalmente em regiões tropicais, onde pequenas variações nos padrões de temperatura e precipitação podem comprometer o desempenho das lavouras (IPCC, 2022; Grigorieva; Livenets; Stelmakh, 2023). Países em desenvolvimento, como o Brasil, estão entre os mais vulneráveis, dada a menor capacidade de acesso a tecnologias de adaptação e mitigação (Pellegrino; Assad; Marin, 2007). Segundo Rezaei et al. (2023), aumentos de temperatura podem reduzir o rendimento agrícola global entre 6,2% e 18,3%, com efeitos mais severos justamente em áreas próximas aos limites térmicos ideais das culturas, como ocorre nas zonas tropicais

Evidências empíricas reforçam que, no Brasil, simulações de cenários de aquecimento indicam perdas de até 39% da área de cultivo da soja para um aumento de 3 °C na temperatura média (Pellegrino; Assad; Marin, 2007). Esses dados apontam para a necessidade de políticas públicas e investimentos voltados à resiliência do setor agrícola frente às mudanças do clima. Essas vulnerabilidades são intensificadas por variações climáticas sazonais, como as causadas pelo fenômeno *El Niño*–Oscilação Sul (ENOS), que promove excesso de chuvas em algumas regiões e seca em outras, impactando de maneira desigual a produção nacional (Araujo, 2012).

A variabilidade climática associada ao fenômeno ENOS exerce influência sobre a produtividade agrícola no Brasil, particularmente, no caso da soja. Em anos de *El Niño*, por

exemplo, há tendência de aumento de chuvas no Sul e redução no Norte e Nordeste, enquanto a *La Niña* provoca seca no Sul e maior volume de precipitações nas regiões Norte e Nordeste (Guimarães; Reis, 2012; CPTEC/INPE, 2025). A produtividade média da soja na Região Sul foi reduzida durante eventos do ENOS ocorridos entre 1970 e 2002, com perdas estimadas de 0,96 toneladas por hectare em anos de *El Niño* e 0,255 toneladas por hectare em anos de *La Niña* (Araujo, 2012).

Um dos estudos pioneiros sobre os efeitos do clima na agricultura brasileira foi conduzido por Sanghi et al. (1997), que avaliaram os impactos de temperaturas extremas por meio de quatro modelos de corte transversal, utilizando informações dos Censos Agropecuários de 1970, 1975, 1980 e 1985. Os autores identificaram que um aumento de 2,5 °C na temperatura média do último mês de cada estação poderia reduzir a produção agrícola nacional entre -2,16% e -7,40%, afetando de forma mais intensa as regiões Centro-Oeste e parte da Norte. Posteriormente, Sanghi e Mendelsohn (2008) expandiram a análise e projetaram que uma elevação de 2 °C na temperatura média, combinada a um acréscimo de 8% na precipitação, poderia resultar em perdas de até 20% da produtividade agrícola no Brasil, com diferenças regionais conforme a interação das variáveis climáticas. Nesse contexto, surge a questão central: como as mudanças climáticas afetam a produção de soja e quais são os impactos econômicos decorrentes para o Brasil?

Este estudo tem como objetivo mensurar os impactos decorrentes das mudanças climáticas sobre a produção de soja no Brasil no período de 2010 a 2023, considerando a influência do fenômeno ENOS. Para isso, será estimada uma função de produção modificada, que incorpora variáveis climáticas, a fim de identificar seus efeitos sobre o valor bruto da produção da soja (VBP) a preços deflacionados para o ano de 2010. Finalmente, a partir dos coeficientes estimados, serão simulados cenários de aquecimento e calculadas as variações percentuais na produção.

A estimação da função de produção é realizada por meio de um modelo de efeitos fixos, o que confere maior robustez às estimativas ao controlar heterogeneidades não observadas entre os municípios, conforme indicado por Cameron e Trivedi (2005) e Wooldridge (2010). As variáveis climáticas utilizadas são georreferenciadas por município, refletindo com precisão as condições climáticas locais. Além disso, seguindo o calendário de plantio e colheita da soja estabelecido pela CONAB (2019), as variáveis climáticas foram organizadas segundo as fases de plantio e colheita, o que contribui para a precisão das análises.

Este estudo apresenta três diferenciais principais: (1) o uso de dados georreferenciados que possibilitam uma análise espacial detalhada das condições climáticas; (2) definição de

período de colheita e plantio pautado no calendário agrícola indicando os meses propícios para realização da colheita e plantio em cada estado brasileiro, agregando maior precisão às estimativas; e (3) a adoção do modelo de painel com efeitos fixos, que permite controlar heterogeneidades regionais não observadas, proporcionando uma análise mais robusta e detalhada dos impactos das mudanças climáticas na produção da cultura.

Esta monografia está organizada em seis capítulos além da introdução. O Capítulo 2 discute os fundamentos teóricos sobre ecofisiologia da soja e o desempenho produtivo do grão no período analisado. O Capítulo 3 traz a revisão de literatura. O Capítulo 4 descreve os dados e a metodologia adotada. O Capítulo 5 apresenta os resultados e, por fim, o Capítulo 6 apresenta as considerações finais.

2 DESEMPENHO ECOFISIOLÓGICO E CARACTERIZAÇÃO DA PRODUÇÃO DE SOJA

Este capítulo tem como objetivo apresentar as principais características relacionadas ao cultivo da soja no Brasil, estruturando-se em duas seções. A primeira aborda a Ecofisiologia da cultura, com ênfase na influência das variáveis climáticas sobre o desenvolvimento e a produção do grão. A segunda seção trata dos aspectos econômicos e produtivos da soja no país.

2.1 ECOFISIOLOGIA DA SOJA

A classificação dos estágios fenológicos da soja, amplamente adotada por técnicos, pesquisadores e produtores, foi proposta por Fehr e Caviness (1977). Os autores dividem esses estágios em duas fases: vegetativa (V) e reprodutiva (R). Essa diferenciação contribui para a padronização das decisões de manejo, uma vez que cada fase apresenta demandas específicas relacionadas ao crescimento e ao desenvolvimento da planta. Tal abordagem permite maior precisão na identificação das necessidades fisiológicas da cultura de soja ao longo do ciclo produtivo.

Além da classificação dos estágios fenológicos, a produção eficiente de soja requer a compreensão das interações entre a planta e o meio ambiente. Nesse contexto, Neumaier et al. (2020) destacam que um melhor entendimento das exigências climáticas da cultura de soja e das relações da água no sistema solo-planta-atmosfera pode contribuir para a redução dos riscos de insucesso da produção do grão. Desse modo, mitiga-se os impactos de adversidades climáticas e otimiza-se a produção.

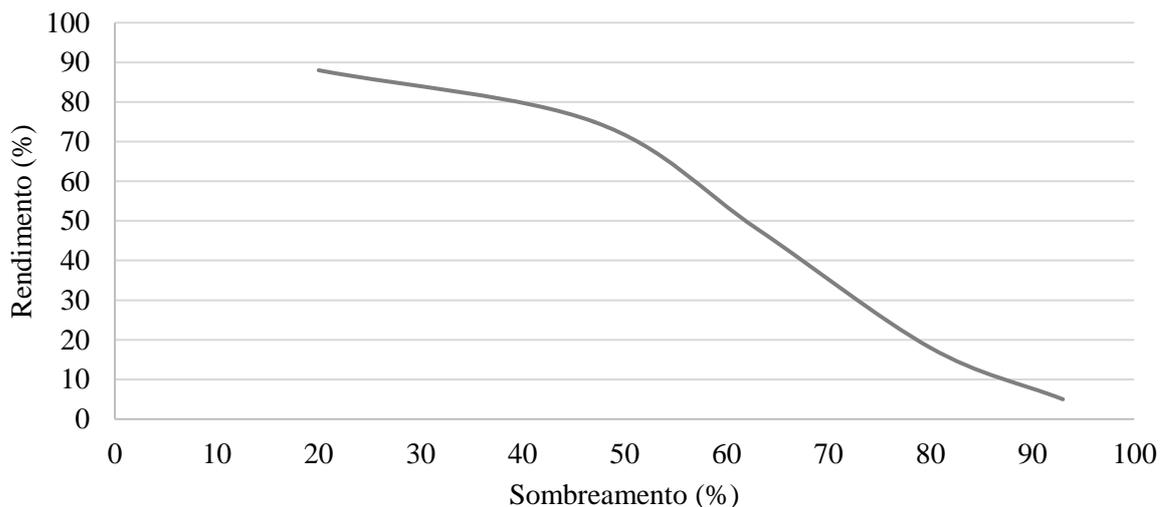
Entre as variáveis atmosféricas, a temperatura exerce papel fundamental no desempenho da cultura da soja ao longo de seu ciclo produtivo. Costa et al. (1992) apontam que temperaturas do solo e do ar em torno de 22 °C, especialmente durante a fase de maturação, favorecem a produção de grãos com alta qualidade sanitária e fisiológica. De forma semelhante, Farias (2007) indica que a faixa ideal para o desenvolvimento da soja situa-se entre 20 °C e 30 °C, sendo a germinação mais eficiente em torno de 25 °C. Temperaturas inferiores a 10 °C podem comprometer o crescimento vegetativo e dificultar o estabelecimento adequado das plantas no solo.

Na fase de floração, segundo Neumaier et al. (2020), temperaturas abaixo de 13 °C podem inibir ou retardar a indução ao florescimento da soja. Ainda, temperaturas elevadas (acima de 40 °C) associadas à alta umidade tendem a antecipar a floração, podendo prejudicar

o crescimento da planta e reduzir a qualidade dos grãos. De acordo com Board e Kahlon (2011) temperaturas superiores a 40 °C pode comprometer a retenção de vagens e a floração, sendo esses efeitos intensificados em cenários de déficit hídrico.

Além da temperatura, outro elemento climático que influencia a produção da soja é a radiação solar. Wahua e Miller (1978) estudaram os efeitos da influência do sombreamento sobre a fixação de nitrogênio e o rendimento da soja. Como resultado, os autores observam que valores moderados de sombreamento, próximos a 20%, favoreceram esses parâmetros. No entanto, o aumento progressivo da restrição de luz levou à redução curvilínea da biomassa aérea e da atividade específica dos nódulos, indicando que a radiação solar exerce papel central na fisiologia da planta (Figura 1).

Figura 1 – Decréscimos de rendimento da soja sob diferentes níveis de sombreamento (0% sombreamento = 100% rendimento de grãos)



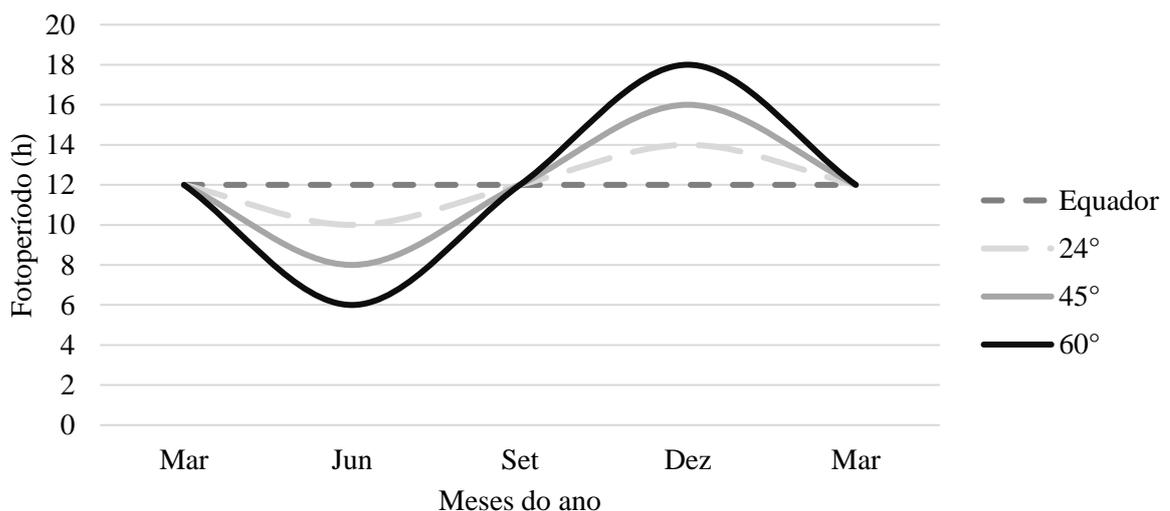
Fonte: Adaptado de Wahua e Miller (1978).

A radiação solar influencia processos fisiológicos como fotossíntese, alongação da haste, expansão foliar, formação de vagens e fixação biológica (Câmara, 2000). Mathew et al. (2000) verificaram que o fornecimento de luz em estágios específicos, especialmente no final do crescimento vegetativo e início da floração, pode elevar o rendimento de sementes, com aumentos de até 252%, sendo o número de vagens por planta o principal fator associado. No entanto, a exposição excessiva à radiação pode provocar fotoinibição, reduzindo a atividade fotossintética, o que leva à ativação de mecanismos de defesa, como a orientação foliar e a fotorrespiração (Jiang et al., 2006). Além disso, Fagan et al. (2007) destacam que a intensidade,

duração e qualidade da luz também afetam aspectos morfológicos, como estatura da planta, indução ao florescimento e ontogenia.

Além dos efeitos da radiação solar em si, a duração do fotoperíodo também exerce influência sobre o rendimento da soja, sendo a sensibilidade à luz variável entre diferentes cultivares (Borthwick; Parker, 1939). Por ser uma planta de dia curto, a soja apresenta um fotoperíodo crítico específico para cada variedade, o que condiciona sua adaptação a distintas latitudes e janelas de plantio (Farias, 2007; Purcell et al., 2014; Neumaier et al., 2020). Com base nas curvas de fotoperíodo ao longo do ano em função da latitude (Figura 2), Farias et al. (2007) ressaltam que a introdução de cultivares com período juvenil longo ou com crescimento indeterminado amplia as possibilidades de cultivo, permitindo flexibilidade na escolha da época de semeadura e localização geográfica.

Figura 2 – Fotoperíodo (em horas) ao longo do ano em função da latitude do local



Fonte: Adaptado de Farias et al. (2007).

Outra variável relevante no rendimento da cultura de soja é o consumo de água. De acordo com Berlato et al. (1992), o maior consumo hídrico da soja ocorre entre a fase de floração e enchimento dos grãos, quando a planta atinge seu maior índice de área foliar e as exigências hídricas diárias variam entre 7 e 8 mm, totalizando de 450 mm a 800 mm ao longo do ciclo. Nessa fase, Farias et al. (2007) aponta que a água é essencial para processos fisiológicos como a regulação térmica e o transporte de nutrientes. Segundo os autores, sinais como murchamento dos tecidos, fechamento dos folíolos e crescimento limitado da planta configuram alguns dos efeitos observados do déficit hídrico.

De acordo com Neumaier et al. (2020), os impactos do déficit hídrico nos estágios reprodutivos da soja podem resultar em abortamento de flores, queda de vagens e má formação de grãos, comprometendo diretamente a produtividade. Ainda segundo os autores, mesmo com o alto nível de tecnificação, a limitação hídrica ainda impõe perdas, particularmente nas regiões Sul, Nordeste e Centro-Oeste.

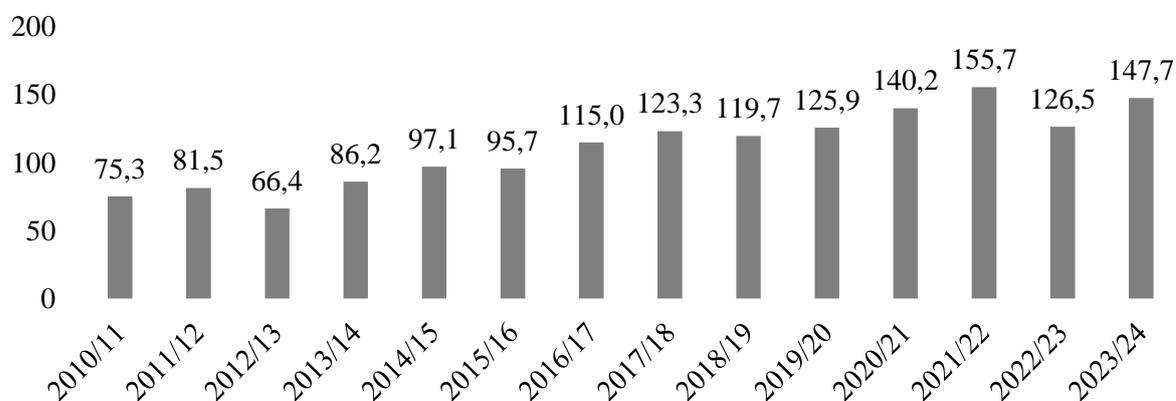
Isso ocorre, pois, a produção de soja brasileira é altamente dependente das chuvas, o que torna relevante o domínio dos processos ecofisiológicos para embasar políticas públicas, tecnologias e estratégias de manejo climático (Monteiro, 2009; Neumaier et al., 2020). Esse domínio é ainda mais importante quando se considera o papel que a soja desempenha na economia do Brasil. A seguir, discute-se a caracterização da produção de soja no país.

2.2 CARACTERIZAÇÃO DA PRODUÇÃO DE SOJA NO BRASIL

Em 2024 o Brasil foi o maior produtor e exportador mundial de soja, posição alcançada diante de constante crescimento na produção, área plantada e produtividade da cultura verificado no período de 2010 até 2024 (CONAB, 2025). De acordo com os dados econômicos disponibilizados, na safra 2024/25, o Brasil produziu aproximadamente 169 milhões de toneladas de soja, representando 40,3% da produção mundial. Desse total, o estado de Mato Grosso produziu 50 milhões de toneladas, o equivalente a 30% da produção nacional e 12% da mundial. Com relação ao comércio internacional, os dados apontam que o Brasil em 2024 exportou aproximadamente 99 milhões de toneladas de soja, responsável por gerar um valor bruto aproximado de U\$43 bilhões.

Com base nas séries históricas disponibilizadas pela CONAB (2025), entre a safra de 2010/11 e a safra de 2023/24 (Gráfico 1), a quantidade de soja produzida no Brasil foi de 75,3 milhões de toneladas para 147,7 milhões de toneladas, o que representa um crescimento de 96%. O Gráfico 1 mostra que entre as safras de 2010/11 e 2023/24 a produção de soja no Brasil apresentou uma tendência de crescimento, com oscilações ao longo do período. As safras de 2021/22 e 2023/24 foram as maiores, com 155,7 e 147,7 milhões de toneladas de soja produzidas. Já as safras de 2012/13 (66,4 milhões de toneladas) e de 2010/11 (75,3 milhões de toneladas) foram as menores.

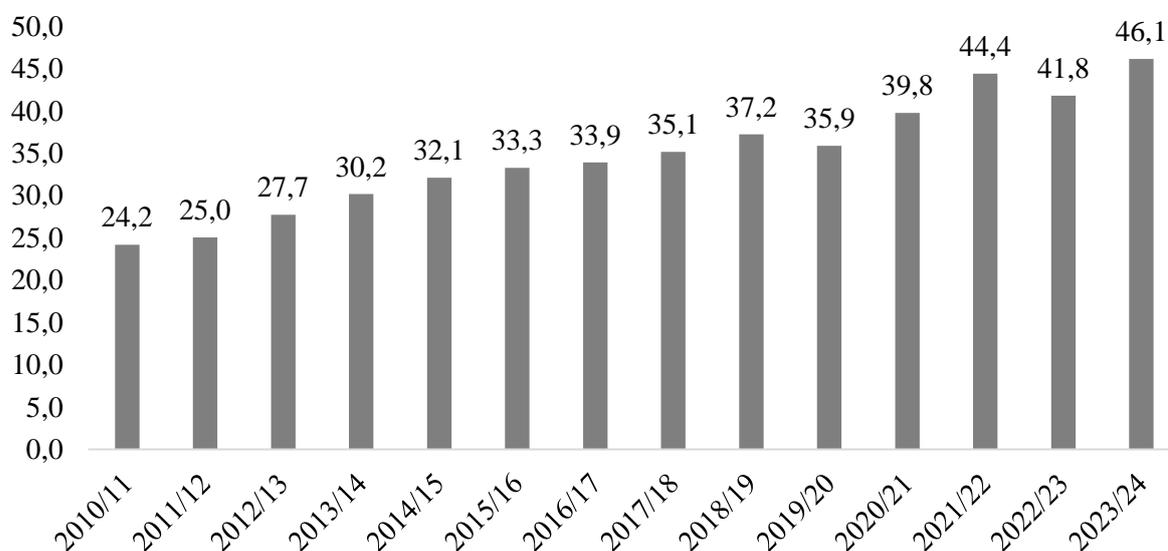
Gráfico 1 – Produção total de soja (em toneladas) no Brasil entre as safras de 2010/11 até 2023/24



Fonte: Elaboração própria com base nos dados disponibilizados pela CONAB (2025).

Em relação a área plantada, entre a safra de 2010/11 e a safra de 2023/24 (Gráfico 2) houve uma tendência de crescimento no valor observado, partindo de 24,2 milhões de hectares para 46,1 milhões de hectares. Segundo Freitas e Mendonça (2016), esse crescimento está fortemente associado à valorização da cultura no mercado internacional e à disponibilidade de terras anteriormente ocupadas com pastagens. Neste último caso, os autores destacam que o crescimento da pecuária bovina favoreceu a conversão de áreas de pastagem ao por permitir a rápida ampliação da produção sem exigir investimentos elevados na abertura de novas áreas.

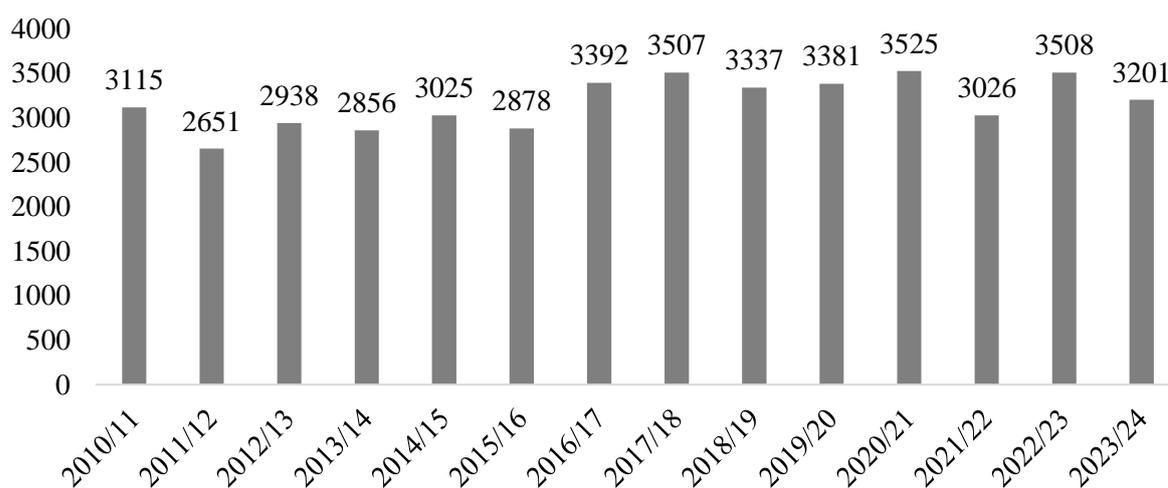
Gráfico 2 – Área plantada de soja (em milhões de hectares) no Brasil entre as safras de 2010/11 até 2023/24



Fonte: Elaboração própria com base nos dados disponibilizados pela CONAB (2025).

Como visto nos gráficos 1 e 2, o crescimento da área plantada foi menor do que a quantidade produzida, o que indica um ganho de produtividade ao longo do tempo. O gráfico 3 mostra que a produtividade da soja no Brasil durante o período analisado oscilou entre 2.651 kg/ha (2011/12) e 3.525 kg/ha (2020/21) e, ainda, entre as safras de 2016/17 e 2023/24 a produtividade manteve-se acima de 3.000 kg/ha. As safras de 2011/12 (2.651 t/ha), 2013/14 (2.856 t/ha) e 2015/16 (2.878 t/ha) apresentaram as menores produtividades. Esses números em consonância com os dados do Gráfico 2 mostra que, apesar da contínua ampliação da área cultivada, a produtividade não responde de modo proporcional, já que fatores exógenos, como as variações climáticas, exercem papel central na cultura do grão.

Gráfico 3 – Produtividade média (em kg/ha) da cultura de soja no Brasil entre as safras de 2010/11 até 2023/24



Fonte: Elaboração própria com base nos dados disponibilizados pela CONAB (2025).

A soja representa um dos pilares do agronegócio brasileiro, com impacto sobre o desenvolvimento econômico e a estrutura produtiva do país. A Tabela 1 mostra o Valor Bruto da Produção (VBP) da soja¹ entre 2010 e 2021. Nesse período, a média de participação da soja no VBP do país foi de 1%. A soja aumentou sua participação no VBP do Brasil nesse período, saindo de 0,6% em 2010 para aproximadamente 2% em 2021.

¹ Aqui considerada apenas o VBP da soja em grão, e não da cadeia de soja como um todo.

Tabela 1 – Participação da soja no Valor Bruto da Produção (em bilhões de reais) do Brasil entre 2010 e 2021

Ano	Soja	Brasil	% no VBP do Brasil
2010	40124	6599149	0.61
2011	52217	7438007	0.70
2012	61520	8223178	0.75
2013	84057	9105053	0.92
2014	90768	9887604	0.92
2015	109170	10226869	1.07
2016	119120	10542067	1.13
2017	128214	11020413	1.16
2018	157189	12010010	1.31
2019	153331	12741791	1.20
2020	209557	13306199	1.57
2021	328235	16581873	1.98

Fonte: Elaboração própria a partir da SCN do IBGE (2025).

Embora tradicionalmente percebida como um produto de baixo valor agregado, a soja tem se consolidado como insumo estratégico em diversas cadeias produtivas, promovendo modernização no campo e atraindo trabalho qualificado (Vieira Filho, 2024). A relevância econômica da soja é reforçada pelos dados do CEPEA/ABIOVE (2023), que indicam que, em 2022, a cadeia da soja e do biodiesel atingiu R\$ 673,7 bilhões, representando 27% do PIB do agronegócio – um aumento frente aos 9% registrados em 2010.

De acordo com Silva (2025), entre 2012 e 2023, o emprego associado à soja e seus derivados cresceu de 1,14 milhão para cerca de 2,32 milhões de postos, dos quais mais de 1,6 milhão estão diretamente ligados a agrosserviços. Esse avanço, segundo o autor, reflete não apenas a expansão da área plantada, mas também a intensificação tecnológica e a formalização da mão de obra rural.

No que se refere ao comércio exterior, a CONAB (2025) mostra que o Brasil exportou entre as safras de 2023/24 e 2024/25 aproximadamente 205 milhões de toneladas, representando cerca de 64% frente ao total de 317 milhões de toneladas produzidas no período. A relação de estoque / consumo de soja verificada no período em questão foi menor do que 1, sendo um valor inferior ao verificado nos períodos anteriores (safras de 2021/22 e 2022/23, com valores de aproximadamente 17 e 11 respectivamente). O comportamento da relação consumo / estoque pode ser justificado pelo crescimento na quantidade interna consumida do grão verificado na safra de 2024/2025, que partiu de 11 milhões de toneladas em 2023/24 para 110 milhões na safra em questão.

3 REVISÃO DA LITERATURA

Este capítulo faz uma revisão da literatura sobre variações climáticas e produção agrícola e está dividido em duas partes. A primeira delas aborda a relação entre mudanças climáticas e produtividade agrícola. A segunda foca nos efeitos das variações climáticas durante a ocorrência dos fenômenos *El Niño* e *La Niña* sobre a produção de soja no Brasil.

A literatura teórica sobre agricultura e mudanças climáticas parte do reconhecimento de que a produção agrícola é sensível a variações de temperatura e precipitação. Modelos de produção agrícola e abordagens econométricas, como a Abordagem Ricardiana, desenvolvida por Mendelsohn, Nordhaus e Shaw (1994), consolidaram a análise dos impactos climáticos ao relacionar condições de clima com a produtividade e o valor das terras agrícolas. Esses trabalhos mostraram que aumentos de temperatura podem ter efeitos distintos conforme a região, sendo que elevações acima de determinados limiares reduzem a produtividade, principalmente em culturas sensíveis como soja, milho e trigo (Rosenzweig; Parry, 1994; Adams et al., 1998).

Outro ponto recorrente nas discussões teóricas refere-se à heterogeneidade espacial e temporal dos impactos. Estudos demonstraram que elevações de temperatura acima de faixas ótimas podem comprometer os rendimentos agrícolas, sobretudo em regiões tropicais, onde a produção já ocorre próxima aos limites fisiológicos das culturas (Deschênes; Greenstone, 2007; Schlenker; Roberts, 2009). Nesse contexto, a literatura ressalta a relevância dos fenômenos climáticos de grande escala, como o *El Niño*-Oscilação Sul (ENOS), que alteram padrões de chuva e regimes térmicos, com efeitos sobre a produtividade e a estabilidade da produção (Mendelsohn; Dinar; Sanghi, 2001).

Além disso, os estudos teóricos destacam a importância da capacidade adaptativa dos produtores e das políticas públicas. Trabalhos indicam que medidas de adaptação, como o uso de variedades mais resistentes, irrigação e diversificação produtiva, podem reduzir a vulnerabilidade agrícola frente às mudanças climáticas. Essa capacidade de adaptação é distribuída de maneira desigual, dependendo do acesso a crédito, tecnologia, infraestrutura e apoio institucional. Assim, o debate teórico enfatiza que os impactos negativos das mudanças climáticas não são uniformes, mas condicionados por fatores econômicos e sociais, reforçando a necessidade de políticas coordenadas para mitigar riscos e garantir a sustentabilidade agrícola. (Seo; Mendelsohn, 2008; Assunção; Chein, 2016).

3.1 MUDANÇAS CLIMÁTICAS E PRODUÇÃO AGRÍCOLA

As mudanças climáticas impactam diretamente a produção agrícola e, conseqüentemente, seus resultados econômicos (Grigorieva; Livenets; Stelmakh, 2023). Segundo o IPCC (2022), esses impactos são particularmente preocupantes nas regiões tropicais, onde desvios nos padrões climáticos já são suficientes para desestabilizar os sistemas agrícolas existentes. Para Pellegrino, Assad e Marin (2007), os países em desenvolvimento são vulneráveis às mudanças climáticas devido ao fato de que o acesso limitado a tecnologias e recursos de adaptação agravam os custos sociais e econômicos.

Segundo Rezaei et al. (2023), o rendimento agrícola mundial pode reduzir entre 6,2% e 18,3% devido a aumentos da temperatura de 2 °C a 4 °C, com efeitos mais pronunciados nas regiões tropicais devido à proximidade das culturas aos seus limites térmicos ótimos. No contexto africano, uma revisão sistemática realizada por Carr et al. (2022) revela que, no conjunto das culturas avaliadas, as mudanças climáticas reduziram a produtividade agrícola em mediana de 6%, com variação entre -18% e +5%, sendo os impactos heterogêneos entre as culturas. O estudo revela que as simulações conduzidas no cenário RCP 2.6 (que projeta um aumento máximo de até 2 °C na temperatura média global até o ano de 2100) apresentaram as menores variações na produtividade agrícola.

Em se tratando do Brasil, Pellegrino, Assad e Marin (2007) simularam os impactos de aumentos de temperatura sobre a produção agrícola a partir de modelos de zoneamento de risco climático. No cenário mais pessimista (aumento da temperatura em 3 °C), haveria perdas de área de cultivo em torno de 7% para o milho, 11% para o feijão, 18% para o arroz, 39% para a soja e 58% para o café.

Para estimar os impactos econômicos de mudanças climáticas na agricultura da região Nordeste, Domingues, Magalhães e Ruiz (2011) utilizaram um modelo de Equilíbrio Geral Computável (EGC). As simulações indicam que no cenário A2 (aumento de temperatura global entre 2 °C e 5,4 °C) todos estados nordestinos teriam redução do PIB estadual, variando entre -18,6% (Pernambuco) e -3,6% (Sergipe) até o ano de 2050. Ainda, no cenário B2 (aumento de temperatura global entre 1,4 °C e 3,8 °C) as projeções apontam para perdas no valor do PIB estadual em todos os estados exceto a Bahia (ganho no PIB estadual em 1,3%), com valores variando entre -13,1% (Pernambuco) e -2,2% (Alagoas) até o ano de 2050. Como resultado, os autores atestam a existência de um potencial de perdas econômicas no Nordeste decorrentes das mudanças climáticas projetadas até 2025, sendo um efeito intenso nos estados mais pobres da região.

O estudo de Souza Ferreira Filho e Moraes (2015) aplicou um modelo de Equilíbrio Geral Computável (EGC) inter-regional para mensurar os efeitos econômicos das mudanças climáticas sobre a agricultura no Brasil. Foram simulados seis cenários, combinando três horizontes temporais (2020, 2050 e 2070) com duas trajetórias de emissões (A2 e B2), de acordo com as diretrizes do IPCC (2008). Os resultados mostraram quedas entre 6% e 10% no PIB do Nordeste, com ressalva para o Piauí, cuja redução acumulada no PIB alcançaria 16,39% até 2070 no cenário de maiores emissões (B2/70). Neste mesmo cenário, o Mato Grosso registrou declínio de 11,20% no PIB, refletindo a vulnerabilidade da região pela dependência do desempenho agrícola às condições climáticas. Em contraste, alguns estados do Sudeste, como Espírito Santo, Rio de Janeiro e São Paulo, apresentaram variações positivas com ganhos inferiores a 2%. Esses resultados reforçam a heterogeneidade dos impactos das mudanças climáticas sobre a economia agrícola brasileira, com maior concentração de perdas nas regiões Nordeste e Centro-Oeste.

Assunção e Chein (2016), por sua vez, utilizaram uma função de produção do tipo Cobb-Douglas para avaliar, em escala municipal, a resposta da produtividade agrícola à variação de temperatura e precipitação. Os autores encontraram que o aumento de 6,57% na temperatura média, combinada com a diminuição de 0,71% na pluviosidade média, leva a uma redução de 18,2% na produtividade agrícola brasileira. Para a região Centro-Oeste, o aumento de 7,47% na temperatura média e a diminuição de 1,54% na pluviosidade, em termos médios, reduz em 28,3% o valor da produção da agricultura. Essa redução é a segunda maior quando comparado com as demais regiões, ficando atrás apenas da região Norte (35%). Entre os estados mais afetados, destacam-se Rondônia (-37,1%), Tocantins (-36,2%) e Amazonas (-36%). Os autores ainda verificaram uma redução média de 32% na produtividade dos estados integrantes do MATOPIBA.

Os impactos das mudanças climáticas sobre a agricultura brasileira foram testados por Feres, Reis e Speranza (2008) utilizando os Censos Agropecuários de 1970, 1975, 1980, 1985 e 1995/96, totalizando 3.124 observações em nível municipal. O estudo aplicou dois modelos econométricos: o ricardiano, que relaciona o valor da terra (R\$/ha) às condições climáticas de médio (2040-2069) e longo prazo (2070-2099), e o de efeitos fixos, que mensura a influência anual do clima sobre a rentabilidade agrícola (R\$/ha). As variáveis de temperatura média (°C) e precipitação (mm/mês) foram organizadas em médias sazonais, permitindo captar variações interanuais. As projeções dos autores mostraram que aumentos próximos a 1 °C e reduções superiores a 50 mm/mês comprometem a rentabilidade agrícola brasileira, com perdas médias

de 3,7% no cenário pessimista (A2) e 0,8% no cenário otimista (B2) de médio prazo, podendo alcançar reduções de 26% e 9,4%, respectivamente, no longo prazo.

Em termos regionais, as perdas de produtividade agrícola relativa para o Norte, Nordeste e o Centro-Oeste foram de, respectivamente, 50%, 20,4% e 46% no cenário A2 de médio prazo, apontam Feres, Reis e Speranza (2008). Ainda neste cenário, no longo prazo, perdas de 124,6%, 51,8% e 161,8% são previstas nas respectivas regiões. Para as projeções do cenário B2, as regiões permanecem prejudicadas: no médio prazo, foram projetadas perdas de 34,8%, 14,3% e 23,2%, enquanto que, no longo prazo, as perdas projetadas seriam de 65,7%, 27,8% e 73,2% para o Norte, Nordeste e Centro-Oeste, respectivamente.

Os resultados encontrados nos estudos citados nesta seção mostram empiricamente que o setor agrícola apresenta forte vulnerabilidade às mudanças climáticas. No Brasil, algumas culturas e regiões são mais afetadas que outras. A região Centro-Oeste e a soja são exemplos de região e cultura com maior sensibilidade a essas mudanças.

3.2 PRODUÇÃO DA SOJA E EVENTOS CLIMÁTICOS ASSOCIADOS AO ENOS

O impacto da variação climática na produtividade da soja no bioma Cerrado, com foco na sub-região do MATOPIBA, foi projetado por Silva et al. (2023) utilizando dados em painel de 1980 a 2018. Foram avaliados 1388 municípios, sendo 322 no MATOPIBA, totalizando mais de 54 mil observações. No período analisado, a temperatura média subiu cerca de 1°C no Cerrado e 5°C no MATOPIBA e, além disso, o aumento da temperatura reduziu a produtividade média na região, com ponto de inflexão em torno de 21°C no caso das culturas desenvolvidas sem irrigação. A precipitação, com média de 1.413 mm, mostrou efeito não linear, com ponto de inflexão entre 1.236 e 1.764 mm. Nesta análise, os modelos de efeitos fixos foram os mais robustos e apontaram que um aumento de 1°C reduz a produtividade da soja entre 1% e 6% nos municípios do Cerrado e entre 8% e 29% nos municípios do MATOPIBA.

Impactos das mudanças climáticas na produtividade da soja nos estados do Pará e Mato Grosso foram verificados por Justino et al. (2013) utilizando dados climáticos diários de temperatura mínima e máxima, precipitação, vento e radiação solar. As simulações consideraram as condições climáticas observadas entre os anos de 2007 e 2008, enquanto que as projeções para o final do século XXI (2080–2100) foram baseadas nos cenários extremos de emissão A2 e B2 do IPCC (2008). A produtividade média simulada da soja foi de aproximadamente 2.720 kg/ha, próxima aos valores reais observados no período de 2007 e 2008, alcançando máximos de 3.120 kg/ha no Pará e 2.570 kg/ha no Mato Grosso. Sob cenários

futuros, o aumento da temperatura (até +6°C para temperatura mínima e +8°C para temperatura máxima no A2) aliado à maior concentração atmosférica de CO₂ (550 ppm no B2 e 770 ppm no A2) resultou em ganhos de produtividade no cenário A2. A redução da precipitação ocasionou queda em torno de 30% na produtividade, mesmo quando considerado o nível de CO₂ verificado em 2008 (380 ppm), evidenciando o efeito negativo do estresse hídrico.

A produtividade da soja, assim como dos demais produtos agrícolas, está condicionada a variáveis climáticas. O padrão com que essas variáveis variam é alterado durante a ocorrência do fenômeno *El Niño*-Oscilação Sul (ENOS), de modo que o desempenho de todo o setor agrícola, incluso a produção soja, está submetido à sazonalidade desse fenômeno (Araújo, 2012).

No Brasil, o *El Niño* tende a provocar aumentos de temperatura, enquanto o *La Niña* diminuição (Guimarães; Reis, 2012). Por um lado, nos anos de *El Niño*, há uma tendência de redução das chuvas no Norte e Nordeste do país e de aumento na região Sul (CPTEC/INPE, 2025). Por outro lado, nos anos de *La Niña*, aumenta-se as chances de seca no Sul e a possibilidade de chuva no Nordeste e Norte aumenta (CPTEC/INPE, 2025).

Araújo (2012) avaliou os impactos da ocorrência desses fenômenos sobre a produção de algumas culturas agrícolas. No caso da soja produzida na região Sul, entre 1970 a 2002, a produtividade média foi de 1,221 toneladas por hectare (t/ha), com reduções estimadas de 0,96 t/ha em anos de *El Niño* e 0,255 t/ha em anos de *La Niña*. De modo geral, todos os estados da região apresentaram maior perda de produtividade média de soja nos anos de *El Niño* do que nos anos de *La Niña*.

Cirino et al. (2015) realizaram uma análise empírica com dados em painel de 1.855 municípios brasileiros no período de 1970 a 2002, a fim de estimar os efeitos dos eventos ENOS sobre o clima e sobre a produtividade agrícola regional. Os resultados indicaram que a produtividade da soja apresenta sensibilidade às anomalias climáticas do ENOS, com efeitos distintos entre as regiões brasileiras. No Norte, a média em anos neutros foi de 0,37 t/ha, caindo 0,18 t/ha em anos de *El Niño* e 0,15 t/ha durante *La Niña*. No Sul, a produtividade média em anos neutros foi de 1,22 t/ha, com reduções de 0,96 t/ha em anos de *El Niño* e 0,32 t/ha em anos de *La Niña*.

Luiz e Silva (2024) verificou os efeitos das fases do fenômeno ENOS sobre a produtividade da soja em Planaltina (DF), utilizando dados meteorológicos diários entre 1974 e 2021 em conjunto com o modelo STICS calibrado para a cultura da soja. As simulações abrangeram 12 diferentes períodos de semeadura, realizados entre setembro e dezembro. Os resultados apontaram que os menores rendimentos foram registrados durante anos de *El Niño*,

especialmente quando a semeadura ocorreu no início da janela recomendada, com quedas de produtividade superiores a 85%. Por sua vez, os maiores rendimentos foram observados em anos com clima neutro ou no final de eventos *El Niño* e *La Niña*. Quando a semeadura foi realizada em novembro e dezembro, as produtividades médias ficaram acima de 4 t/ha, evidenciando que o momento da semeadura aliado ao tipo de evento climático influencia o desempenho da soja.

Os efeitos do fenômeno ENOS sobre a produtividade da soja no bioma Cerrado foi avaliado por Neto e Artiaga (2023) através de simulações com o modelo CROPGRO-Soybean, utilizando dados climáticos históricos de 1961 a 2020, totalizando 60 safras. O estudo contemplou 14 municípios distribuídos em seis estados, representando diferentes condições climáticas do Cerrado. Durante o *El Niño*, os menores valores médios ocorreram em Dourados (MS) (2,4 t/ha) e Balsas (MA) (2,5 t/ha), enquanto os maiores foram observados em Poxoréu (MT) (3,6 t/ha) e Uberaba (MG) (3,6 t/ha). Na fase *La Niña*, os menores rendimentos médios foram registrados em Dourados (2,3 t/ha) e João Pinheiro (MG) (2,5 t/ha), com os maiores novamente em Uberaba (3,8 t/ha) e Poxoréu (3,7 t/ha). Já sob neutralidade, o pior desempenho médio foi verificado em Dourados (1,9 t/ha), enquanto Uberaba (3,8 t/ha) apresentou a maior média entre todas as fases. Os resultados indicam que, embora as fases do ENOS influenciem a produtividade da soja, os efeitos variam entre os municípios.

Esta seção apresentou evidências empíricas de como a cultura de soja pode ser afetada na ocorrência do fenômeno ENOS. Ademais, verificou-se que esses efeitos podem variar conforme a localidade e a fase desenvolvimento da soja. Assim, para avaliar os impactos de variáveis climáticas sobre a produtividade da soja durante a ocorrência do fenômeno ENOS, é preciso controlar a estágio de desenvolvimento da cultura e a região em que ela está sendo cultivada. O capítulo seguinte apresenta a metodologia empregada neste estudo.

4 METODOLOGIA

Este estudo tem como objetivo analisar os efeitos das variáveis climáticas sobre o valor bruto da produção de soja no Brasil, considerando os valores observados de produção bruta (em R\$, deflacionado a preços de 2010) e área plantada de soja (em hectares) durante o período de 2010 a 2023. A análise é realizada sob diferentes condições climáticas, incluindo anos de neutralidade, bem como períodos caracterizados pela ocorrência dos fenômenos *El Niño* e *La Niña*.

Para tanto, foi adotado um modelo econométrico com dados em painel, o qual permite capturar simultaneamente a variação temporal e a heterogeneidade entre os municípios produtores. Essa abordagem é especialmente vantajosa por possibilitar o controle de fatores não observáveis que podem influenciar a produtividade agrícola, como características estruturais locais e práticas de manejo. A base de dados utilizada contempla informações anuais em nível municipal, abrangendo variáveis agroclimáticas - como temperatura média, precipitação e radiação solar - além de indicadores relacionadas à Oscilação Sul (ENOS), que sinalizam a presença dos eventos *El Niño* e *La Niña*. Uma inovação metodológica deste trabalho diz respeito à separação das variáveis de temperatura e precipitação nas etapas de plantio e colheita da soja, o que possibilita captar as variações de produção nas etapas mais críticas do ciclo produtivo.

4.1 MODELO TEÓRICO

Os estudos sobre produção agrícola comumente utilizam duas abordagens metodológicas: abordagem Ricardiana e a Função de Produção. Mendelsohn et al. (1994) desenvolveram um modelo, conhecido como Abordagem Ricardiana, que analisa o efeito do clima sobre o valor e o rendimento da terra. Os autores explicam que, ao medir diretamente o valor ou os rendimentos agrícolas, é possível estimar os impactos diretos do clima sobre os rendimentos de diferentes culturas, bem como a substituição indireta de diferentes insumos e vários tipos de adaptações potenciais a quaisquer climas. Essa abordagem baseia-se no pressuposto de que o valor da terra é determinado pelo valor presente esperado dos fluxos agrícolas futuros.

Contudo, em países como Brasil, é possível que o valor da terra reflita além dos ganhos esperados da agricultura. Assunção (2008) encontra evidências de que o valor das terras no país aumentou mais do que as taxas de aluguel durante períodos de instabilidade econômica. Além

disso, Deschênes e Greenstone (2007) argumentam que a Abordagem Ricardiana pode produzir estimativas sensíveis a escolhas sobre variáveis de controle, amostra e ponderação. Sendo assim, este estudo opta por utilizar a abordagem da Função de Produção.

Essa abordagem é tradicionalmente especificada como uma função de produção em que variáveis climáticas são consideradas como insumos de produção (Assunção; Chein, 2016). Conforme Chambers (1988), a relação mais geral entre produção e insumos pode ser expressa da seguinte forma:

$$Y = f(X) \quad (1)$$

Em que Y representa um produto que é originado pela combinação de um vetor de N insumos X . A Equação 1 é amplamente utilizada na literatura na sua forma funcional Cobb-Douglas. Essa forma é apropriada para este estudo, pois permite captar a elasticidade da produção em relação a diferentes insumos, além de ser flexível para inclusão de variáveis adicionais, como fatores climáticos. Varian (2003) destaca que essa função possibilita modelar o efeito da variação dos insumos sobre a produção total. A equação geral da função Cobb-Douglas pode ser definida como:

$$Y = AT^\alpha L^\beta K^\gamma \quad (2)$$

Em que Y é o produto, T é o fator de produção terra, L é o trabalho, K é o capital investido (máquinas, insumos, infraestrutura) e os parâmetros α , β e γ são as elasticidades da produção em relação a cada insumo (Varian, 2003).

Para incorporar os elementos temperatura, precipitação, radiação solar e vento nos modelos de produção, a função geral expressa na Equação 2 pode ser estendida para incluir variáveis climáticas, assumindo a seguinte formulação:

$$Y = T^\alpha L^\beta K^\gamma \cdot f(Z) \quad (3)$$

Em que $f(Z)$ é uma função que representa o efeito dos fatores climáticos sobre a produção.

A Equação 3 neste estudo representa a função de produção da soja. Em outras palavras, a produção da soja depende dos insumos de produção (terra, trabalho e capital) combinados com as variáveis climáticas diversas e com um fator tecnológico exógeno. No Brasil, não há dados anuais para as variáveis de capital e trabalho, esses dados são censitários, ou seja, só estão disponíveis a cada dez anos. Estudos como os de Tirfi e Oyekale (2022) e Li (2023) enfrentaram limitação semelhante, pois não possuíam as séries temporais de alguns dos insumos clássicos de produção. Diante da limitação de dados, e seguindo esses dois estudos, o modelo teórico desta pesquisa pode ser escrito como:

$$Y = T^\alpha \cdot f(Z) \quad (4)$$

Ou seja, a produção da soja está em função da terra plantada e de um conjunto de variáveis climáticas.

Com relação a produtividade da soja, a qualidade e manejo do solo estão diretamente relacionadas com a capacidade de incorporação e uso das terras disponíveis por parte dos produtores e, de acordo com o debate de Neumaier et al. (2020), práticas adequadas que promovem o desenvolvimento saudável da cultura de soja ajudam a mitigar os estresses fisiológicos e nutricionais, garantindo maior rendimento do grão.

Além disso, as variáveis climáticas também desempenham papel crucial no rendimento da soja, sendo que para o caso da temperatura é possível verificar um efeito positivo dentro do intervalo ótimo (20 °C a 30 °C), enquanto que temperaturas extremas (menos de 13 °C ou acima de 30 °C) comprometem o crescimento e a formação dos grãos (Costa et al., 1992; Farias et al., 2007; Board; Kahlon, 2011; Neumaier et al., 2020). Na literatura científica, as variáveis de precipitação e umidade são consideradas benéficas até determinados níveis, porém, tanto o déficit quanto o excesso hídrico podem prejudicar as fases reprodutivas da cultura, impactando negativamente o rendimento (Berlato et al., 1992; Farias et al., 2007; Neumaier et al., 2020).

No caso da variável de radiação solar, autores convergem de que existe uma influência positiva no processo de fotossíntese e no desenvolvimento da planta, com efeito benéfico até certo limite, após o qual a saturação luminosa e o aumento do risco de doenças podem reduzir a produtividade (Wahua e Miller, 1978; Mathew et al., 2000; Câmara, 2000; Jiang et al., 2004; Fagan et al., 2007).

Finalmente, a velocidade do vento e a evaporação têm efeitos negativos quando em níveis excessivos. Ventos fortes, por exemplo, especialmente após o estágio de reprodução R5, causam acamamento, danos físicos às folhas e facilitam a disseminação de pragas e doenças, reduzindo o rendimento da soja (Gazzoni, 1974; Monteiro, 2009). Por fim, uma evaporação elevada diminui a disponibilidade de água no solo, aumentando o estresse hídrico e prejudicando potencialmente o desenvolvimento da cultura (Monteiro, 2009).

No Quadro 1 é possível observar um resumo da relação esperada de cada variável presente no modelo proposto neste estudo e as respectivas fontes.

Quadro 1 – Relação esperada entre terra, variáveis climáticas e a produção de soja

Variável	Relação Esperada	Fonte
Terra	Positiva quando associado ao manejo adequado do solo e fertilidade; práticas	NEUMAIER et al. (2020)

	integradas de manejo são essenciais para garantir altos rendimentos da soja.	
Temperatura	Negativa ou positiva, dependendo do intervalo térmico, com a temperatura ótima variando entre 20 °C e 30 °C. Temperaturas extremas reduzem a produtividade.	COSTA et al. (1992); FARIAS (2007); BOARD; KAHLON (2011); NEUMAIER et al. (2020)
Precipitação	Positiva até certo limite, depois negativa. Excessos e escassez prejudicam o rendimento e produtividade.	BERLATO et al. (1992); FARIAS; NEPOMUCENO; NEUMAIER (2007); NEUMAIER et al. (2020)
Umidade	Positiva até um nível ótimo; déficits durante a fase reprodutiva comprometem severamente a produtividade.	BERLATO et al. (1992); FARIAS; NEPOMUCENO; NEUMAIER (2007); NEUMAIER et al. (2020)
Radiação Solar	Positiva até certo limite; excessos podem reduzir fotossíntese e favorecer doenças.	WAHUA; MILLER (1978); MATHEW et al. (2000); CÂMARA (2000); JIANG et al. (2004); FAGAN et al. (2007)
Velocidade do Vento	Negativa se excessiva (causa acamamento, danos foliares e disseminação de pragas e doenças).	GAZZONI (1974); MONTEIRO (2009)
Evaporação	Negativa (aumenta o déficit hídrico e reduz a disponibilidade de água nas fases críticas de desenvolvimento da soja).	MONTEIRO (2009)

Fonte. Elaboração própria.

Nesta seção, foram discutidas as relações teóricas entre as variáveis edáficas e climáticas que influenciam a produtividade da soja, fundamentando o modelo conceitual que norteia esta pesquisa. As contribuições da literatura evidenciam a complexidade das interações entre fatores climáticos, destacando a importância do manejo integrado desses elementos para otimizar o rendimento da cultura. Nas seções seguintes, serão apresentadas as especificações metodológicas e os dados utilizados para a modelagem empírica, detalhando como essas variáveis serão incorporadas na análise dos efeitos climáticos sobre a produção de soja no Brasil.

4.2 MODELO EMPÍRICO

Com base na formulação teórica apresentada anteriormente, que adotou uma função de produção Cobb-Douglas estendida para incluir variáveis climáticas, o modelo empírico deste estudo pode ser representado pela seguinte equação funcional:

$$\ln(Y)_{it} = \beta_0 + \beta_1 \ln(T)_{it} + \sum_{j=1}^{10} \beta_{2j} X_{it,j} + \sum_{k=7}^9 \beta_{3k} \ln(Z_{it,k}) + \alpha_i + \gamma_t + \epsilon_{it} \quad (5)$$

Em que $\ln(Y)_{it}$ é o logaritmo natural da variável dependente, ou seja, do valor da produção bruta de soja no município i no ano t . O $\ln(T)_{it}$ é o logaritmo natural da área plantada no município i no ano t . O $X_{it,j}$ é um vetor que inclui algumas variáveis climáticas do modelo, referentes ao município i no ano t ; o índice j , que vai de 1 a 10, representa as seguintes variáveis: temperatura e precipitação nos períodos de plantio e colheita (primavera/verão e outono/inverno), além da umidade e dos termos quadráticos dessas variáveis. O vetor $\ln(Z_{it,k})$ é o logaritmo natural das variáveis radiação, evaporação e velocidade do vento no município i no ano t ; o índice k identifica individualmente cada uma dessas variáveis. No modelo, os termos α_i e γ_t representam o ano t e o município i , respectivamente. O termo ϵ_{it} é o resíduo e o coeficiente β_0 é o intercepto ou a constante do modelo. Por fim, β_1 , β_{2j} e β_{3k} são os coeficientes associados às variações em cada uma das variáveis explicativas do modelo.

A escolha da forma funcional em modelos econométricos é uma etapa crucial na estimação, especialmente quando se busca interpretar elasticidades e capturar relações não lineares entre variáveis. Segundo Benoit (2011), a transformação logarítmica facilita a interpretação dos coeficientes, permitindo que as estimativas representem variações percentuais da variável dependente em resposta a variações percentuais nas variáveis explicativas.

A variável área plantada, por sua vez, é amplamente reconhecida na literatura como um dos principais determinantes da produção agrícola, sendo frequentemente utilizada como medida da escala de cultivo. Em contexto internacional, Aragón, Oteiza e Rud (2021) analisaram agricultores de subsistência no Peru e identificaram que, em anos de temperaturas extremas, o aumento da área cultivada foi uma estratégia compensatória, embora com perda de produtividade por hectare. No Brasil, Parré, Chagas e Arends-Kuenning (2024) demonstraram que o tamanho da propriedade e o uso da terra influenciam a diversificação e a renda agrícola, reforçando a importância da área plantada em modelos produtivos.

Além disso, a relação entre temperatura e produtividade agrícola é vista na literatura científica como não linear, o que justifica a utilização de termos quadráticos nas especificações econométricas. Schlenker et al. (2006) evidenciaram que variações extremas de temperatura reduzem significativamente a produção, indicando que os efeitos marginais podem se inverter conforme o valor da variável.

Resultados semelhantes foram observados por Araujo (2012) e por Cirino et al. (2015) para a cultura da soja no Brasil, cuja produtividade apresentou queda acentuada quando as temperaturas em anos de *El Niño* e *La Niña* foram maiores comparadas com anos neutros. Dessa forma, a aplicação de logaritmos e de termos quadráticos no modelo contribui tanto para a robustez estatística quanto para uma melhor representação das decisões dos produtores agrícolas frente às condições climáticas e econômicas.

Como destacado por Cameron e Trivedi (2005), a teoria econômica frequentemente não fornece orientações específicas sobre qual forma funcional adotar, cabendo ao pesquisador determinar a especificação mais adequada com base no comportamento dos dados e no objetivo do estudo. Os autores, contudo, alertam que optar por uma forma funcional inadequada pode resultar em estimadores viesados e inconsistentes, comprometendo a validade das inferências. Nesse sentido, buscando parcimônia entre a interpretação e as relações que as variáveis explicativas possuem com a dependente, a forma funcional expressa na Equação 5 é a mais adequada para este estudo. Abaixo, a Equação 6 representa a versão com todas variáveis presentes no modelo definido neste estudo:

$$\begin{aligned}
 \ln(Y)_{it} = & \beta_0 + \beta_1 \ln(T)_{it} + \beta_{2,1} \text{TempPlant}_{it} + \beta_{2,2} \text{TempPlant}^2_{it} \\
 & + \beta_{2,3} \text{TempColheita}_{it} + \beta_{2,4} \text{TempColheita}^2_{it} + \beta_{2,5} \text{PrecPlant}_{it} \\
 & + \beta_{2,6} \text{PrecPlant}^2_{it} + \beta_{2,7} \text{PrecColheita}_{it} + \beta_{2,8} \text{PrecColheita}^2_{it} \\
 & + \beta_{2,9} \text{Umidade}_{it} + \beta_{2,10} \text{Umidade}^2_{it} + \beta_{3,7} \ln(\text{Radiação})_{it} \\
 & + \beta_{3,8} \ln(\text{Vento})_{it} + \beta_{3,9} \ln(\text{Evaporação})_{it} + \alpha_i + \gamma_t + \epsilon_{it}
 \end{aligned}
 \tag{6}$$

4.3 DADOS EM PAINEL

Esta seção está dividida em duas subseções. A primeira apresenta os principais modelos de dados em painel. A segunda, por sua vez, apresenta os métodos de estimação para os modelos de dados em painel.

4.3.1 Modelos de dados em painel

A base de dados construída para este estudo é um painel de dados. Ela apresenta observações repetidas para um mesmo corte transversal (*cross-section*) ao longo do tempo

(Wooldridge, 2010). Em outras palavras, a base deste estudo possui observações repetidas para um mesmo conjunto de municípios ao longo do período analisado (2010 a 2023).

A ausência de observações para alguns municípios em determinados anos caracteriza este painel como desbalanceado, conforme discutido por Gujarati e Porter (2009). Além disso, dado que o número de unidades (2685 municípios) é muito maior que o número de períodos (14 anos), o painel em questão também é classificado como curto (Gujarati; Porter, 2009).

O uso de dados em painel melhora a precisão das estimativas em comparação com os dados *cross-section*, pois o aumento do número de observações proporciona ganhos de graus de liberdade, o que tende a melhorar a eficiência das estimativas (Cameron; Trivedi, 2005).

Também, a possibilidade de utilizar várias observações ao longo do tempo para cada unidade observada permite modelar dinâmicas temporais e controlar características não observadas que são constantes ao longo do tempo (Cameron; Trivedi; 2005; Gujarati; Porter, 2009), do contrário as estimativas podem ser viesadas se essas observações forem correlacionadas com os regressores (Cameron; Trivedi, 2005).

Além disso, dados em painel melhoram a identificação das relações causais, permitindo analisar o efeito das variáveis independentes sobre a dependente ao longo do tempo. Wooldridge (2010) destaca que esses dados são, especialmente, úteis para estudar efeitos de variáveis não manipuláveis, como políticas econômicas ou mudanças climáticas, como é o caso deste estudo.

Por fim, Cameron e Trivedi (2005) afirmam que dados em painel possibilitam testes, como o de Hausman, para escolher entre modelos de efeitos aleatórios e efeitos fixos, permitindo uma escolha mais aprimorada sobre como modelar de forma consistente a variabilidade entre as unidades e ao longo do tempo.

Uma representação mais geral dos dados em painel deste estudo, na forma de um modelo linear, pode ser expressa como:

$$y_{it} = \alpha_{it} + \mathbf{X}'_{it}\boldsymbol{\beta}_{it} + u_{it}, \quad i = 1, \dots, N, t = 1, \dots, T \quad (6)$$

Em que y_{it} representa a variável dependente (produção da soja); α_{it} é o intercepto; \mathbf{X}'_{it} representa o vetor $k \times 1$ de variáveis explicativas (insumo de produção e variáveis climáticas); e u_{it} o termo de erro no município i , que vai de 1 a N, neste caso a 2685, no tempo t , que vai de 2010 a 2023, neste estudo. Esse modelo permite que tanto α_{it} quanto os coeficientes ($\boldsymbol{\beta}_{it}$) de inclinação variem no tempo e entre os municípios. E isso é um problema que compromete a estimação desse modelo, já que o número de parâmetros a ser estimado é muito superior ao número de observações (Cameron; Trivedi, 2005).

Diante disso, Cameron e Trivedi (2005) apontam para a necessidade de impor restrições ao grau em que α_{it} e β_{it} variam ao longo de t e entre i , bem como ao comportamento de u_{it} . Nesse sentido, diferentes modelos de estimação, tais como modelo de dados empilhados (*Pooled*), Efeitos Aleatórios (EA) e Efeitos Fixos (EF), podem ser utilizados.

O modelo *Pooled* simplesmente empilha todas as observações, desprezando a natureza das *cross-sections* e séries temporais dos dados (Gujarati; Porter, 2009). Já o modelo de EA supõe que os interceptos específicos de cada unidade i são extraídos aleatoriamente de uma população maior. O modelo de EF, por sua vez, utiliza um método de transformação das variáveis em desvios em relação às médias de cada unidade i (Gujarati; Porter, 2009).

Entre esses modelos, o mais restritivo deles é o *Pooled*, que especifica coeficientes constantes no tempo e entre indivíduos ou unidades (Cameron; Trivedi, 2005), de modo que o modelo da Equação 1, pode ser escrito como:

$$y_{it} = \alpha + \mathbf{X}'_{it}\beta_{it} + u_{it} \quad (7)$$

Se esse modelo estiver especificado corretamente e os seus regressores não forem correlacionados com o termo de erro, ele pode ser estimado consistentemente pelo método de Mínimos Quadrados Ordinários Empilhados (*Pooled Ordinary Least Squares* – POLS) (Cameron; Trivedi, 2005; Wooldridge, 2010):

$$E(\mathbf{X}'_{it}u_{it}) = 0, \quad i = 1, \dots, N, \quad t = 1, \dots, T \quad (8)$$

Cameron e Trivedi (2005), todavia, destacam que é provável que o termo de erro esteja correlacionado ao longo do tempo para um dado indivíduo. Nesse caso, os erros padrão usualmente reportados não devem ser utilizados, pois podem apresentar um viés significativamente para baixo. Os autores adicionam que o estimador POLS é inconsistente se o modelo de efeitos fixos for o mais adequado.

Uma variação simples do modelo da Equação 7 permite que os interceptos variem entre os indivíduos e ao longo do tempo, enquanto os parâmetros de inclinação permanecem constantes:

$$y_{it} = \alpha_i + \gamma_t + \mathbf{X}'_{it}\beta + u_{it} \quad (9)$$

Em que α_i captura as variações específicas para cada indivíduo e γ_t reflete as variações ao longo do tempo. Esse modelo possui parâmetros que podem ser consistentemente estimados quando tanto $N \rightarrow \infty$ quanto $T \rightarrow \infty$ (aqui, N é o número de observações; e T , o número de períodos). Em painéis curtos, onde N cresce, mas T não, os γ_t podem ser estimados de forma consistente, permitindo a inclusão de *dummies* de tempo nos regressores.

O desafio é estimar os parâmetros β , controlando pelos N interceptos de indivíduo α_i . Uma alternativa seria usar *dummies* para grupos de observações, como por estado, mas neste modelo opta-se por incluir um conjunto completo de interceptos individuais. Isso pode gerar problemas à medida que N aumenta, pois o número de parâmetros cresce rapidamente, tornando a estimativa mais difícil e potencialmente inconsistente (Cameron; Trivedi, 2005).

Para abordar essa limitação, Cameron e Trivedi (2005) sugerem utilizar o modelo de efeitos específicos para cada unidade. Esse modelo permite que os interceptos difiram entre as unidades *cross-section*, mantendo constantes os coeficientes de inclinação, de modo que:

$$y_{it} = \alpha_i + \mathbf{X}'_{it}\boldsymbol{\beta} + u_{it} \quad (10)$$

Em que o termo de erro u_{it} é assumido como independente e identicamente distribuído (i.i.d.) tanto entre as unidades i quanto ao longo do tempo t .

De acordo com os autores, essa formulação é uma maneira mais compacta de expressar o modelo da Equação 9, em que quaisquer variáveis *dummies* de tempo são incorporadas aos regressores \mathbf{X}'_{it} . O α_i é uma variável aleatória que captura a heterogeneidade não observada específica de cada unidade *cross-section*. Por fim, Cameron e Trivedi (2005) adotam a suposição de exogeneidade estrita para o modelo da Equação 5, isto é, a expectativa condicional do erro u_{it} , dado α_i e \mathbf{X}'_{it} , é zero para todo t :

$$E[u_{it}|\alpha_i, \mathbf{X}'_{it}] = 0, \quad t = 1, \dots, T \quad (11)$$

Há duas variantes do modelo apresentado na Equação 10. A primeira delas, o modelo de EF, trata α_i como uma variável aleatória não observada que pode estar potencialmente correlacionada com os regressores observados \mathbf{X}'_{it} (Cameron; Trivedi, 2005). Se os efeitos fixos estão presentes e são correlacionados com \mathbf{X}'_{it} , estimadores, como POLS, tornam-se inconsistentes. Nesse caso, métodos de estimação alternativos que eliminem α_i são necessários para garantir a estimação consistente de $\boldsymbol{\beta}$ em um painel curto.

A outra variante do modelo da Equação 10, denominada modelo de EA, assume que os efeitos individuais não observáveis são α_i variáveis aleatórias distribuídas independentemente dos regressores (Cameron; Trivedi, 2005). O modelo de EA faz suposições adicionais à apresentada na Equação 11:

$$\alpha_i \sim N(\alpha, \sigma_\alpha^2) \quad (12)$$

$$u_{it} \sim N(0, \sigma_u^2) \quad (13)$$

Ou seja, tanto os efeitos aleatórios α_i quanto o termo de erro u_{it} são i.i.d (independentemente e identicamente distribuídos).

4.3.2 Estimadores de dados em painel

Para estimar os coeficientes β dos modelos de dados em painel, diversos métodos de estimação são aplicados, cada um com características específicas que influenciam a escolha dependendo dos dados e das suposições adotadas. Entre as abordagens mais comuns, destacam-se o método de *Pooled Ordinary Least Squares* (POLS), os estimadores *Between*, *Within* (Efeitos Fixos), de Primeiras Diferenças e de EA. Os estimadores POLS e *Between* não exploram as características especiais dos dados em painel. O primeiro leva em conta as unidades e o tempo nas estimações. O segundo se caracteriza como um caso especial do POLS, em que $T=1$ (Cameron; Trivedi, 2005).

Em um painel curto, o estimador *within* de efeitos fixos elimina as variações entre as unidades e concentra-se nas diferenças dentro de cada unidade ao longo do tempo, expressando os valores das variáveis dependentes e dos regressores como desvios de seus respectivos valores médios (Gujarati; Porter, 2009). Isso é feito utilizando a variação dos dados ao longo do tempo.

Considere o modelo da Equação 10, que inclui o modelo da Equação 7 como um caso especial em que $\alpha_i = \alpha$. Em seguida, ao tirar a média ao longo do tempo, obtém-se $\bar{y}_i = \alpha_i + \bar{X}_i' \beta + \bar{u}_i$ e subtraí-la do modelo da Equação 10, tem-se o modelo *within* (Cameron; Trivedi, 2005):

$$y_{it} - \bar{y}_i = (\mathbf{X}_{it} - \bar{\mathbf{X}}_i)' \beta + (u_{it} - \bar{u}_i), \quad i = 1, \dots, N, t = 1, \dots, T \quad (14)$$

Em que os termos α_i são eliminados. Ao aplicar o estimador de MQO na Equação 14, tem-se o estimador de efeitos fixos *within*. Esse método fornece estimativas consistentes de β no modelo de efeitos fixos, enquanto os estimadores POLS e *between* não. Uma grande limitação da estimação dentro do modelo *within* é que os coeficientes dos regressores invariantes no tempo não são identificados, já que se $\mathbf{X}_{it} = \mathbf{X}_i$, então $\bar{\mathbf{X}}_i = \mathbf{X}_i$, de modo que $(\mathbf{X}_{it} - \bar{\mathbf{X}}_i) = 0$ (Cameron; Trivedi, 2005).

O estimador de primeiras diferenças mede a relação entre as variações individuais nos regressores e na variável dependente ao longo de um período, eliminando a heterogeneidade constante em cada unidade de observação ao comparar as variáveis em dois períodos consecutivo. Para $T = 2$, os estimadores de primeiras diferenças e *within* são os mesmos, para $T > 2$, o estimador *within* é o mais eficiente entre os dois (Cameron; Trivedi, 2005; Gujarati; Porter, 2009).

O estimador de EA inclui no termo de erro o efeito específico do indivíduo, de modo que a Equação 10 pode ser vista como uma regressão de y_{it} sobre \mathbf{X}'_{it} , com o termo de erro

composto $u_{it} = \alpha_i + \varepsilon_{it}$, sendo α_i e ε_{it} i.i.d (Cameron; Trivedi, 2005). Se o modelo de EA for estimado por MQO, as estimativas serão ineficientes; o método é o de Mínimos Quadrados Generalizados (MQG) (Gujarati; Porter, 2011)². O Quadro 2 resume as propriedades dos principais estimadores conforme modelo assumido.

Quadro 2 – Estimadores e modelos comuns para estrutura de dados em painel

Estimadores de β	Modelo Assumido		
	<i>Pooled</i>	Efeitos Aleatórios	Efeitos Fixos
POLS	Consistente	Consistente	Inconsistente
Between	Consistente	Consistente	Inconsistente
Within	Consistente	Consistente	Consistente
Primeiras Diferenças	Consistente	Consistente	Consistente
Efeitos Aleatórios	Consistente	Consistente	Inconsistente

Fonte: Cameron e Trivedi (2005).

A escolha adequada do modelo para dados em painel é crucial, pois impacta significativamente a consistência e a eficiência das estimativas de β . O modelo assumido determina quais estimadores são consistentes e quais não são. Por exemplo, se o modelo correto for de efeitos fixos, estimadores como POLS ou de EA produzem estimativas inconsistentes como pode ser visto no Quadro 2. Para guiar a escolha entre modelos, podem ser realizados testes estatísticos específicos.

O teste de Breusch e Pagan é usado para decidir entre o modelo POLS e o de EA. Conforme Cameron e Trivedi (2005), a hipótese nula (H_0) do teste é de que os erros são i.i.d (independentemente e identicamente distribuídos), isto é, não há efeitos aleatórios. Ainda de acordo com os autores, se o teste rejeita a hipótese nula, conclui-se que há evidência para a existência de efeitos aleatórios, e o modelo de EA é o mais adequado.

Para painéis curtos, testes formais para a presença de efeitos fixos específicos para cada indivíduo não são possíveis devido ao problema dos parâmetros incidentais. Não é viável testar se N parâmetros são iguais a zero quando há apenas $N \times T$ e T é pequeno. Em vez disso, utiliza-se o teste de Hausman para verificar a H_0 de efeitos aleatórios contra a alternativa de efeitos fixos (Cameron; Trivedi, 2005). Se o teste rejeitar a H_0 , então os efeitos aleatórios (não observados) provavelmente estão correlacionados com uma ou mais variáveis observadas do modelo, o que torna o estimador de EF preferível ao de EA (Gujarati; Porter, 2009). Esses testes

² Para maiores detalhes sobre o estimador de EA, ver Cameron e Trivedi (2005) e Wooldridge (2010).

desempenham um papel essencial na escolha do modelo mais adequado, permitindo captar as particularidades dos dados analisados e assegurando maior robustez às inferências realizadas.

Sendo alguns dos possíveis problemas presentes no método escolhido neste estudo, o caso de heterocedasticidade e da autocorrelação dos erros são mitigados ao utilizar uma matriz de variância robusta aos erros, garantindo que os desvios-padrão das estimativas permaneçam consistentes mesmo na presença dessas violações dos pressupostos clássicos.

Além disso, reconhece-se a possibilidade de existência de variáveis omitidas que não variam ao longo do tempo, mas que influenciam as decisões agrícolas em cada município. Para controlar esses efeitos não observáveis específicos de cada localidade, o modelo faz uso de efeitos fixos e efeitos aleatórios.

A abordagem de efeitos fixos permite isolar as características invariáveis de cada município, enquanto os efeitos aleatórios auxiliam na modelagem de componentes aleatórios que podem influenciar a produtividade agrícola. Dessa forma, busca-se capturar de maneira mais precisa os efeitos regionais não observados, aumentando a robustez das inferências sobre a influência das variáveis climáticas na produção e no uso da terra para a soja.

Diante do exposto, a definição do modelo econométrico apropriado é fundamental para garantir a validade e a precisão das estimativas obtidas a partir dos dados em painel. A adoção de efeitos fixos neste estudo, aliada ao uso de matriz robusta à heterocedasticidade e autocorrelação dos erros, bem como a realização de testes estatísticos como Breusch-Pagan e Hausman, permite mitigar problemas clássicos de especificação e assegurar maior confiabilidade às inferências.

Com isso, torna-se possível capturar de forma mais acurada as heterogeneidades não observadas entre os municípios e isolar o impacto das variáveis climáticas sobre a produção de soja no Brasil, oferecendo subsídios empíricos relevantes para a compreensão dos efeitos das mudanças climáticas na atividade agrícola.

4.4 BASE DOS DADOS E VARIÁVEIS

O modelo proposto neste estudo é um modelo de produção em uma versão modificada que visa estimar os efeitos da produção de soja, definida como o valor bruto da sua produção em reais (R\$) a preços de 2010, em função de dois tipos de variáveis: insumo de produção e variáveis climáticas.

O insumo considerado aqui é a terra, representado pela área plantada de soja, e as variáveis climáticas, que são: as médias de temperatura e de precipitação ao longo das estações primavera e verão, representando o período de plantio; e das estações outono e inverno, representando o período de colheita da soja; a média da velocidade do vento e o total acumulado de umidade, evaporação e radiação solar. Os dados estão em formato de painel e foram extraídos para o período de 2010 a 2023 para todos os municípios produtores de soja do Brasil.

Os dados relacionados à soja – área plantada e valor bruto da produção – foram extraídos da Pesquisa Agrícola Municipal (PAM) do Instituto Brasileiro de Geografia e Estatística (IBGE, 2023). O valor da produção da soja a preços de 2010³ é a variável dependente do modelo proposto. Ao longo de 2010 e 2023, alguns municípios não apresentaram valores para o valor bruto da produção, esses municípios foram automaticamente excluídos do estudo, de modo que permaneceram na base 2706 municípios, que efetivamente produziram soja durante pelo menos um ano do período analisado. Por fim, calculou-se o logaritmo natural da produção da soja e da área plantada.

Em relação às variáveis climáticas, dados climáticos mensais desses 2706 municípios foram coletados utilizando o sistema de reanálises *ERA5-Land* do programa *Copernicus Climate Data Store* (CCDS, 2023). Os dados foram extraídos via *Application Programming Interface* (API) do CCDS utilizando a linguagem *Python* na ferramenta *Google Colab*. As variáveis extraídas foram as seguintes: temperatura média do ar a 2 metros do solo (em graus Kelvin – °K) e temperatura média do ponto de orvalho a 2 metros do solo (°K), que representa a umidade do ar; radiação solar incidente na superfície acumulada (em joules por metros – J/m²); média dos componentes do vento nas direções leste (u10) e oeste (v10), ambos em metros por segundo (m/s); precipitação acumulada (em metros – m); e evaporação acumulada (m).

Algumas transformações foram feitas nessas variáveis a fim de melhorar a compreensão e seguir as unidades de medida mais comuns na literatura de economia agrícola. Nesse sentido, as variáveis de temperatura foram transformadas em Celsius (°C), de acordo com a seguinte fórmula, como indicado pelo CCDS (2023):

$$\text{Temperatura em Celsius} = \text{Temperatura em Kelvin} - 273,15 \quad (15)$$

³ O valor bruto da produção em reais foi deflacionado pelo Índice geral de preços - disponibilidade interna (IGP-DI) calculado pela Fundação Getúlio Vargas (FGV) e disponível no sítio do IPEADATA (2025). A Tabela A 1 do Apêndice contém os dados desse índice.

Por sua vez, as variáveis de direção de componente de direção do vento (u_{10} e v_{10}) foram combinadas a fim de gerar a variável velocidade do vento (ECMWF, 2023):

$$\sqrt{(u^2 + v^2)} \quad (16)$$

Adicionalmente, as variáveis precipitação total e evaporação total, que estavam em metros (m), foram transformadas em milímetros (mm):

$$\text{Valor em mm} = \text{Valor em m} * 1000 \quad (17)$$

Após o tratamento individual de dessas variáveis climáticas, elas deram origem a outras variáveis utilizadas no modelo. Calculou-se média mensal para cada ano do período analisado (2010-2023) de todas as variáveis climáticas, exceto temperatura e precipitação. Para essas duas variáveis, calculou-se a média sazonal para cada ano, foram consideradas dois períodos agrícolas: plantio (primavera e verão) e colheita (outono e inverno). Também foram criadas o quadrado dessas variáveis e da umidade. As demais variáveis entraram no modelo na forma logarítmica, no caso da evaporação o logarítmico do seu módulo, já que a transformação logarítmica se aplica somente a valores positivos.

A terceira etapa de tratamento dos dados consistiu em combinar os dados de produção de soja e os dados climáticos. Embora inicialmente houvessem 2706 municípios em ambas as bases, nem todos apresentavam dados climáticos completos. Assim, após a combinação, a base consolidada incluiu dados de 2685 municípios, representando a produção de soja no Brasil.

Por fim, à nova base foi adicionada uma variável categórica que indica a ocorrência dos eventos climáticos *El Niño* Oscilação Sul (ENOS), com base nos critérios do Centro de Previsão Climática (do inglês, *Climate Prediction Center* – CPC) da Administração Nacional Oceânica e Atmosférica (do inglês, *National Oceanic and Atmospheric Administration* – NOAA).

De acordo com o CPC (2023), a ocorrência de eventos ENOS é determinada por meio do Índice Oceânico Niño (*Oceanic Niño Index* – ONI) definido pela média móvel trimestral da anomalia de temperatura da superfície Equatorial do Oceano Pacífico. Quando a anomalia apresenta por, no mínimo, cinco períodos de três meses consecutivos valores superiores a $0,5^{\circ}\text{C}$, o ENOS é caracterizado como *El Niño*, quando inferiores a $-0,5^{\circ}\text{C}$ ocorre o *La Niña*.; caso contrário há neutralidade. O Quadro 3 apresenta a classificação dos ENOS de 2010 a 2023, com base nesses critérios. Em cinza escuro estão destacados os valores das anomalias iguais ou superiores a $0,5^{\circ}\text{C}$; em cinza claro, as anomalias menores ou iguais a -5°C ; e, em branco, os valores entre esses dois intervalos.

**Quadro 3 – Anomalias trimestrais da Temperatura da Superfície do Mar (TSM)
para os anos de 2010 a 2023**

Ano	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ	Caracterização ENOS
2010	1,5	1,2	0,8	0,4	-0,2	-0,7	-1,0	-1,3	-1,6	-1,6	-1,6	-1,6	<i>La Niña</i>
2011	-1,4	-1,2	-0,9	-0,7	-0,6	-0,4	-0,5	-0,6	-0,8	-1,0	-1,1	-1,0	<i>La Niña</i>
2012	-0,9	-0,7	-0,6	-0,5	-0,3	0,0	0,2	0,4	0,4	0,3	0,1	-0,2	Neutro
2013	-0,4	-0,4	-0,3	-0,3	-0,4	-0,4	-0,4	-0,3	-0,3	-0,2	-0,2	-0,3	Neutro
2014	-0,4	-0,5	-0,3	0,0	0,2	0,2	0,0	0,1	0,2	0,5	0,6	0,7	Neutro
2015	0,5	0,5	0,5	0,7	0,9	1,2	1,5	1,9	2,2	2,4	2,6	2,6	<i>El Niño</i>
2016	2,5	2,1	1,6	0,9	0,4	-0,1	-0,4	-0,5	-0,6	-0,7	-0,7	-0,6	<i>La Niña</i>
2017	-0,3	-0,2	0,1	0,2	0,3	0,3	0,1	-0,1	-0,4	-0,7	-0,8	-1,0	Neutro
2018	-0,9	-0,9	-0,7	-0,5	-0,2	0,0	0,1	0,2	0,5	0,8	0,9	0,8	Neutro
2019	0,7	0,7	0,7	0,7	0,5	0,5	0,3	0,1	0,2	0,3	0,5	0,5	<i>El Niño</i>
2020	0,5	0,5	0,4	0,2	-0,1	-0,3	-0,4	-0,6	-0,9	-1,2	-1,3	-1,2	<i>La Niña</i>
2021	-1,0	-0,9	-0,8	-0,7	-0,5	-0,4	-0,4	-0,5	-0,7	-0,8	-1,0	-1,0	<i>La Niña</i>
2022	-1,0	-0,9	-1,0	-1,1	-1,0	-0,9	-0,8	-0,9	-1,0	-1,0	-0,9	-0,8	<i>La Niña</i>
2023	-0,7	-0,4	-0,1	0,2	0,5	0,8	1,1	1,3	1,6	1,8	1,9	2,0	<i>El Niño</i>

Fonte: CPC (2023).

Nota: As letras maiúsculas representam as iniciais dos meses do ano, por exemplo, na segunda coluna, DJF representa o trimestre **D**ezembro, **J**aneiro e **F**evereiro.

O Quadro 4 apresenta a descrição detalhada das variáveis utilizadas na análise empírica, incluindo suas definições, unidades de medida, natureza (produtiva ou climática), forma de tratamento estatístico e respectivas fontes de dados.

Quadro 4 – Descrição das variáveis e fonte dos dados

Variável	Descrição	Unidade de medida	Tipo de variável	Forma	Fonte
Produção	Valor bruto da produção de soja a preços de 2010	R\$	Dependente	Logaritmo natural	PAM (IBGE, 2023)
Área	Área plantada de soja	ha	Insumo de produção	Logaritmo natural	PAM (IBGE, 2023)
Temperatura	Média da temperatura dos períodos agrícolas de plantio (primavera e verão) e de colheita (outono e inverno)	°C	Climática	Nível	ERA5-Land (CCDS, 2023)
Precipitação	Média da precipitação acumulada dos períodos agrícolas: plantio (primavera e verão) e colheita (outono e inverno)	mm	Climática	Nível	ERA5-Land (CCDS, 2023)
Velocidade do vento	Média da velocidade do vento	m/s	Climática	Logaritmo natural	ERA5-Land (CCDS, 2023)

Radiação solar	Média da radiação solar incidente acumulada na superfície	J/m ²	Climática	Logaritmo natural	ERA5-Land (CCDS, 2023)
Umidade	Média da temperatura do ponto de orvalho	°C	Climática	Nível	ERA5-Land (CCDS, 2023)
Evaporação	Média da evaporação acumulada	mm	Climática	Logaritmo natural	ERA5-Land (CCDS, 2023)
ENOS	Variável categórica que caracteriza o evento ENOS (1, se <i>El Niño</i> ; 2, se <i>La Niña</i> ; e 3, se neutro)	–	Climática	Categórica	(CPC, 2023)

Fonte: Elaboração própria.

5 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados deste estudo. A seção 5.1 apresenta as principais estatísticas descritivas das variáveis utilizadas. A seção 5.2 apresenta e discute as estimativas do modelo econométrico adotado neste estudo. Por fim, a seção 5.3 apresenta e discute de modo mais detalhado os efeitos das variáveis temperatura e precipitação sobre a produção da soja, em termos percentuais a partir dos resultados das estimativas apresentadas na seção 5.2.

5.1 ESTATÍSTICAS DESCRITIVAS

A Tabela 2 evidencia uma marcante heterogeneidade na produção de soja entre os municípios brasileiros ao longo do período analisado. A média anual do valor da produção por município foi de aproximadamente R\$36.500, com um desvio padrão de R\$102.000, o que revela disparidades na contribuição econômica da cultura da soja nas diferentes localidades.

A análise conforme as fases do fenômeno ENOS permite observar que, tanto nos anos classificados como *El Niño* (2015, 2019 e 2023) quanto nos anos de *La Niña* (2010, 2011, 2016 e 2020-2022), a média da produção municipal foi superior ao valor médio do período total, alcançando R\$39.800 e R\$38.900, respectivamente. Essa elevação média, no entanto, veio acompanhada de um aumento na variabilidade entre os municípios (com desvios de R\$110.000 e R\$112.000, respectivamente), sugerindo que os eventos extremos associados ao ENOS não impactam os territórios de forma uniforme e podem acentuar desigualdades na produção da soja.

A partir dos dados deste estudo, observa-se que a produção média da soja nos municípios brasileiros apresenta variações relevantes ao longo das fases do ENOS. Ainda que a produção total tenha aumentado nos anos de *El Niño* e *La Niña*, essa elevação nem sempre reflete ganhos diretos de produtividade, uma vez que também houve ampliação da área cultivada em determinados contextos, refletindo em diferentes efeitos líquidos na produtividade (Da Silva et al., 2021).

Esses resultados dialogam com a literatura, que destaca a sensibilidade da produtividade da soja às oscilações climáticas, especialmente em regiões como o Sul e Centro-Oeste do país. Embora o setor sojícola demonstre resiliência em termos agregados, os impactos negativos sobre o rendimento por hectare em determinadas regiões reforçam a importância de políticas de adaptação regionalizadas frente aos eventos associados ao ENOS (Araujo, 2012).

Os dados também revelam informações sobre a área plantada de soja nos municípios brasileiros entre 2010 e 2023. A área média anual plantada por município foi de aproximadamente 15,13 mil hectares, com um desvio padrão de 38,66 mil hectares, evidenciando uma alta variabilidade espacial entre os produtores. Essa variabilidade se reflete nos extremos observados, que vão de áreas mínimas de 0,001 mil hectares até extensões com 635 mil hectares cultivados. Nos anos sob influência do fenômeno *El Niño*, a área plantada média foi superior, atingindo 16,02 mil hectares, acompanhada de um desvio padrão mais elevado (40,74 mil hectares), o que sugere um estímulo à expansão da soja mesmo em condições climáticas adversas. Já durante os anos de *La Niña*, observou-se uma média inferior, de 15,09 mil hectares, com um desvio padrão de 38,48 mil hectares, indicando uma possível retração e maior cautela dos produtores na ampliação das áreas de cultivo.

Estudos demonstram que as mudanças climáticas podem comprometer a aptidão agrícola no Brasil, sobretudo em culturas como a soja (Pellegrino; Assad; Marin, 2007). A projeção de perda de até 39% da área apta ao cultivo de soja revela a magnitude da vulnerabilidade climática do setor, principalmente nas áreas hoje consideradas economicamente estratégicas para a produção nacional. Esses dados ajudam a contextualizar a elevada variabilidade observada neste estudo, além de indicar que os ganhos médios registrados nos anos de *El Niño* e *La Niña* não devem ser interpretados como uniformemente positivos, mas como expressões de uma distribuição espacial desigual dos impactos climáticos.

Apesar dessas oscilações, os resultados indicam que os produtores mantiveram – e, em alguns casos, até aumentaram – a área plantada de soja mesmo diante das variações climáticas associadas ao ENOS. Essa resistência produtiva, no entanto, deve ser analisada com cautela à luz de estudos que apontam efeitos econômicos acumulativos das mudanças climáticas, especialmente em regiões vulneráveis como o Nordeste brasileiro (Domingues; Magalhães; Ruiz, 2011).

Os dados da Tabela 3 também evidenciam padrões climáticos distintos associados aos eventos *El Niño* e *La Niña* durante os períodos críticos do ciclo da soja: plantio e colheita. Em anos de *El Niño*, observou-se uma elevação nas temperaturas médias tanto no plantio (24,30 °C) quanto na colheita (20,94 °C), valores superiores aos registrados nos anos de *La Niña* (23,52 °C e 20,13 °C, respectivamente) e acima das médias do período total. A elevação térmica, especialmente no início do ciclo, pode acelerar o desenvolvimento vegetativo, mas também aumenta o risco de déficits hídricos, principalmente quando associada à redução nas chuvas – como evidenciado pela precipitação média de apenas 4,48 mm/dia nos anos de *El Niño*, bem abaixo dos 5,39 mm/dia observados em anos de *La Niña*.

As condições climáticas adversas no período de plantio impactam diretamente o potencial produtivo da soja, sendo demonstrado por estudos prévios. Simulações realizadas por Alberto et al. (2006) mostraram que, mesmo em um único município, como o caso de Santa Maria (RS), os rendimentos de soja sob restrição hídrica variaram drasticamente entre as safras, reforçando o papel determinante da disponibilidade de água nos estágios iniciais do ciclo. Análises empíricas apontam para elevada sensibilidade da produtividade da soja às anomalias climáticas do ENOS, com perdas expressivas nas regiões Sul e Norte do país, especialmente em anos de *El Niño*. Tais evidências ajudam a interpretar os padrões identificados neste estudo, sugerindo que os efeitos negativos sobre a produtividade podem ser mais intensos em regiões onde as alterações nos regimes de chuva e temperatura afetam o calendário agrícola tradicional (Araujo, 2012; Cirino et al., 2015).

A análise detalhada a seguir buscará aprofundar essa relação, examinando os efeitos específicos das variações climáticas sobre a produção municipal da soja no país. O estudo enfocará as respostas gerais da produção frente aos fenômenos *El Niño* e *La Niña*, destacando as tendências observadas e as implicações para a resiliência do setor agrícola brasileiro diante das mudanças climáticas.

Tabela 2 – Estatísticas descritivas

Variável	Geral (2010-2023)				<i>El Niño</i> (2015, 2019 e 2023)				<i>La Niña</i> (2010, 2011, 2016 e 2020-2022)			
	Média	Desvio padrão	Mínimo	Máximo	Média	Desvio padrão	Mínimo	Máximo	Média	Desvio padrão	Mínimo	Máximo
Produção (em mil reais)	36500.00	102000.00	0.001	2250000.00	39800.00	110000.00	1.18	2010000.00	38900.00	112000.00	0.001	2250000.00
Área plantada (em mil ha)	15.13	38.66	0.001	635.00	16.02	40.74	0.001	625.9	15.09	38.48	0.001	620.00
Temperatura plantio	23.74	2.19	16.56	29.93	24.30	2.28	17.43	29.69	23.52	2.19	16.56	29.93
Temperatura colheita	20.37	4.10	11.48	29.85	20.94	3.86	12.74	29.31	20.13	4.29	11.48	29.85
Precipitação plantio	5.24	1.73	0.46	13.90	4.48	1.98	0.46	11.75	5.39	1.70	1.03	13.90
Precipitação colheita	2.31	1.73	0.05	12.52	2.14	1.69	0.09	10.74	2.12	1.62	0.06	12.52
Umidade	16.07	2.06	10.73	23.63	16.77	1.90	11.88	23.55	15.59	2.11	10.73	23.63
Radiação solar (em mil)	17000.00	3428.54	5751.45	22200.00	14000.00	5461.60	5751.45	22100.00	17600.00	2030.57	11300.00	21900.00
Velocidade do vento	1.03	0.30	0.25	3.83	1.00	0.31	0.25	3.44	1.02	0.29	0.26	3.74
Evaporação	-2.78	0.65	-4.66	-0.42	-2.33	0.98	-4.55	-0.42	-2.80	0.46	-4.66	-1.26

Fonte: Elaboração própria.

A produção da soja, como mostrado na Tabela 3, varia conforme a presença ou não dos fenômenos climáticos *El Niño* e *La Niña*. As Figuras 4, 5 e 6 apresentam mapas que mostram a distribuição espacial das variáveis produtividade da soja, a temperatura na fase de plantio e a precipitação na fase de plantio da soja, respectivamente. Na construção dos mapas, foram selecionados os anos de 2010, 2015, 2018 e 2023, por se caracterizarem como anos de *La Niña*, *El Niño*, neutro e *La Niña* (Quadro 3) respectivamente, permitindo uma análise comparativa dos impactos dos diferentes padrões do fenômeno ENOS.

A representação espacial foi construída por meio da técnica de mapeamento coroplético⁴, utilizando classes definidas com base na distribuição empírica dos dados, por meio do *Software RStudio*. Municípios classificados como “Produção nula” (ou NA) correspondem a registros inferiores a uma tonelada ou à ausência de produção no período analisado. A análise integrada dessas figuras possibilita verificar como o comportamento climático em diferentes contextos pode favorecer ou limitar a produtividade da soja.

A Figura 3 apresenta mapas de produtividade da soja (valores deflacionados para 2010), permitindo observar a variação regional da renda agrícola por hectare (R\$/ha). A Figura 4 mostra os padrões espaciais da temperatura média (em °C) durante o plantio, evidenciando áreas sujeitas ao estresse térmico. Já a Figura 5 destaca a distribuição da precipitação média (em mm), essencial para avaliar a disponibilidade hídrica no momento da semeadura.

Em 2010, sob influência do fenômeno *La Niña*, a precipitação média durante o plantio foi elevada em grande parte das regiões produtoras, especialmente no Centro-Oeste e Sudeste, com volumes que variaram entre 6,3 mm e mais de 11 mm por dia. As temperaturas foram amenas, entre 21°C e 24°C em áreas centrais, o que favorece a germinação e o crescimento inicial da soja (Farias et al., 2007). No entanto, os níveis de produtividade econômica foram baixos em várias regiões, com destaque para o Nordeste e parte do Norte, onde valores ficaram abaixo de R\$1.500/ha. Isso sugere a existência de limitações tecnológicas ou estruturais que impediram maior aproveitamento das condições climáticas favoráveis (Neumaier et al., 2020).

No ano de 2015, marcado por um intenso *El Niño*, observou-se uma redução expressiva da precipitação em grandes áreas do Centro-Oeste, Sul e Nordeste, com médias abaixo de 6 mm por dia. As temperaturas médias superaram os 26°C em várias regiões produtoras, aumentando o risco de estresse térmico e hídrico sobre as lavouras (Farias et al., 2007). Ainda assim, a produtividade apresentou melhora em relação a 2010, com regiões como o Sul e partes do

⁴ Um mapa coroplético é um mapa temático que usa cores ou sombreamento para representar valores ou magnitudes de uma variável em áreas geográficas definidas.

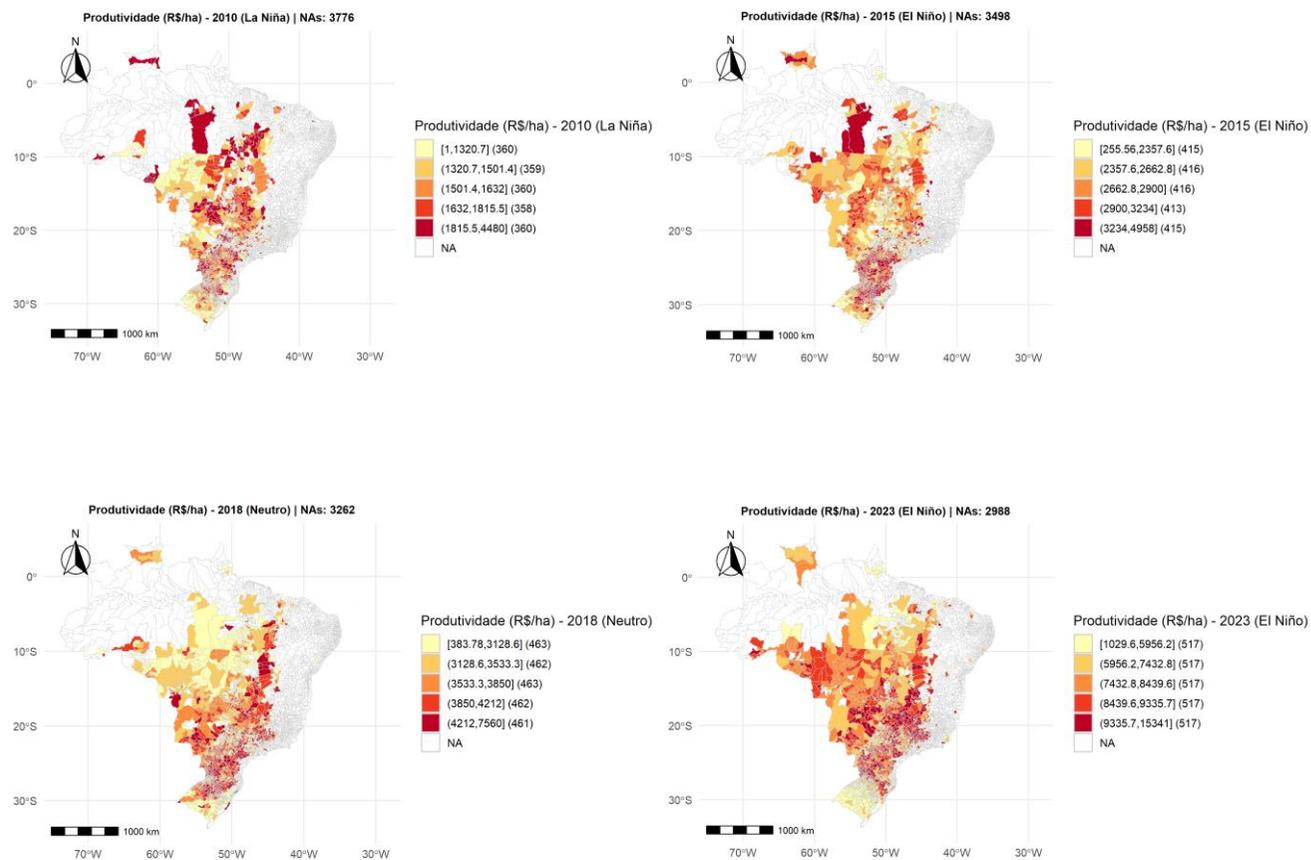
MATOPIBA registrando valores superiores a R\$2.900/ha. Isso pode refletir avanços em práticas de manejo, uso de cultivares adaptadas a condições adversas ou expansão da irrigação (Monteiro, 2009).

Em 2018, com condições climáticas consideradas neutras, a distribuição das chuvas foi regular em grande parte do território, com valores médios variando de 4,5 mm a mais de 12 mm por dia nas áreas centrais e sulistas. As temperaturas oscilaram dentro de uma faixa ideal para a soja, entre 22°C e 26°C, e, em conjunto com a boa disponibilidade hídrica, favoreceram o desenvolvimento inicial da lavoura. Essa combinação climática resultou em melhor desempenho produtivo em comparação aos dois anos anteriores, com diversas regiões alcançando entre R\$4.000/ha e R\$7.500/ha, especialmente no Sul e parte do Sudeste (Farias et al., 2007; Neumaier et al., 2020).

Em 2023, novamente sob *El Niño*, as condições climáticas foram as mais extremas da série analisada. A precipitação foi severamente reduzida em quase todo o território, com médias diárias inferiores a 3 mm em amplas regiões do Nordeste e do MATOPIBA. As temperaturas ultrapassaram os 29°C em diversos municípios, especialmente no Norte e Centro-Oeste, configurando um cenário climático desafiador. Apesar disso, a produtividade atingiu patamares elevados, com muitas áreas registrando entre R\$6.000/ha e R\$15.000/ha, evidenciando a notável resiliência do setor agrícola, provavelmente em função da intensificação tecnológica, como o uso de sementes mais tolerantes ao calor e técnicas mais eficientes de manejo (Neumaier et al., 2020).

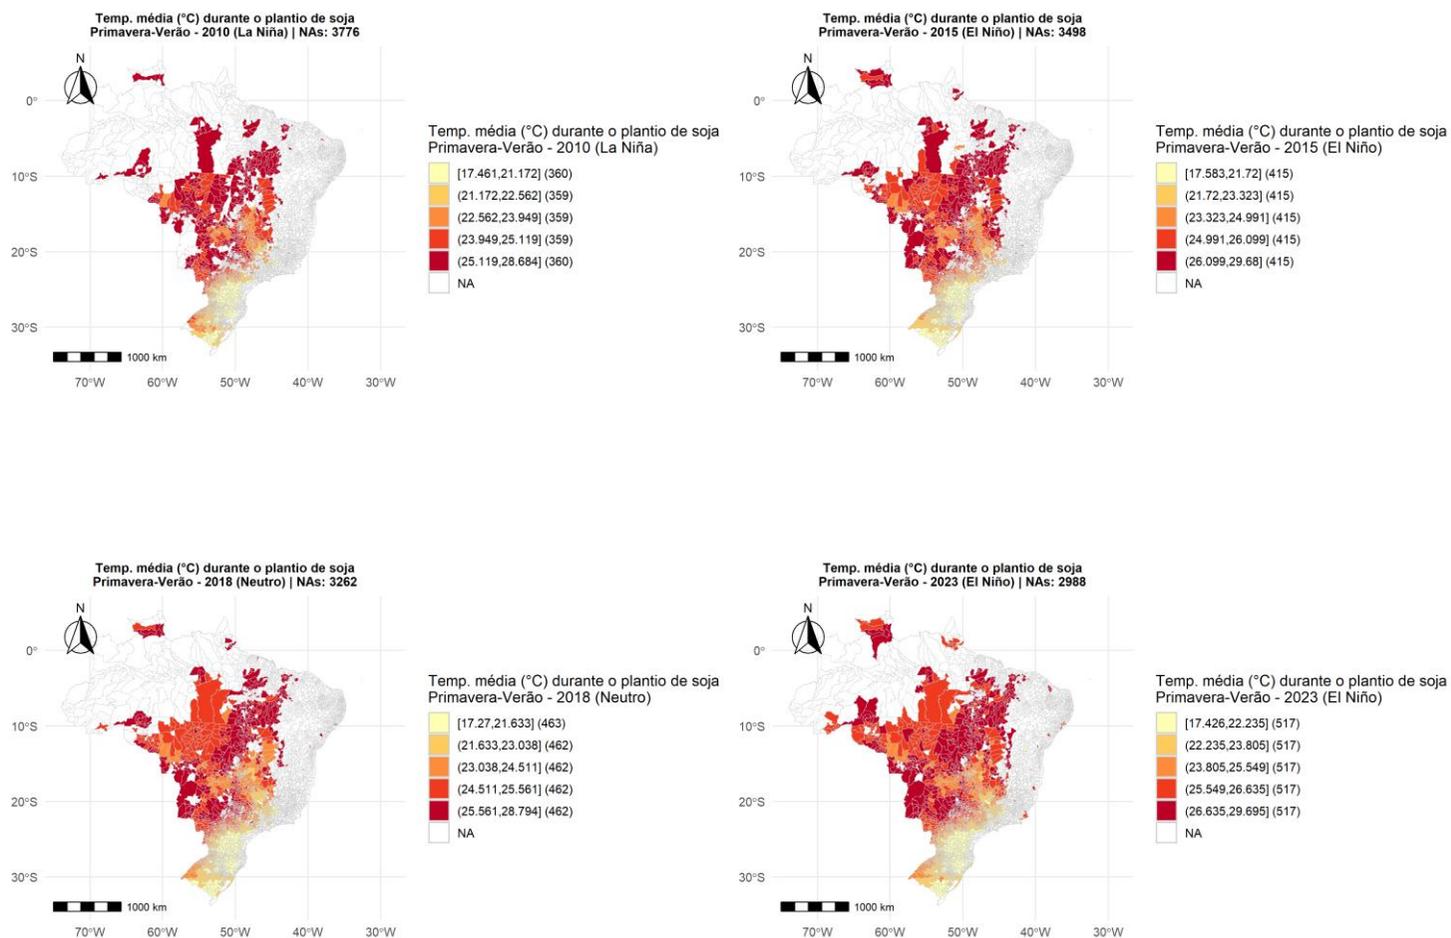
A produção de soja no Brasil tem se expandido cada vez mais, conforme se observa na Figura 3. Essa expansão pode ser uma resposta a uma maior variabilidade climática. A próxima seção apresenta e discute as estimativas encontradas neste estudo sobre o efeito das variáveis climáticas associadas ao fenômeno ENOS sobre a produtividade de soja no Brasil.

Figura 3 - Mapas de produtividade média (em R\$ / hectare) para os municípios produtores de soja no Brasil nos anos destacados



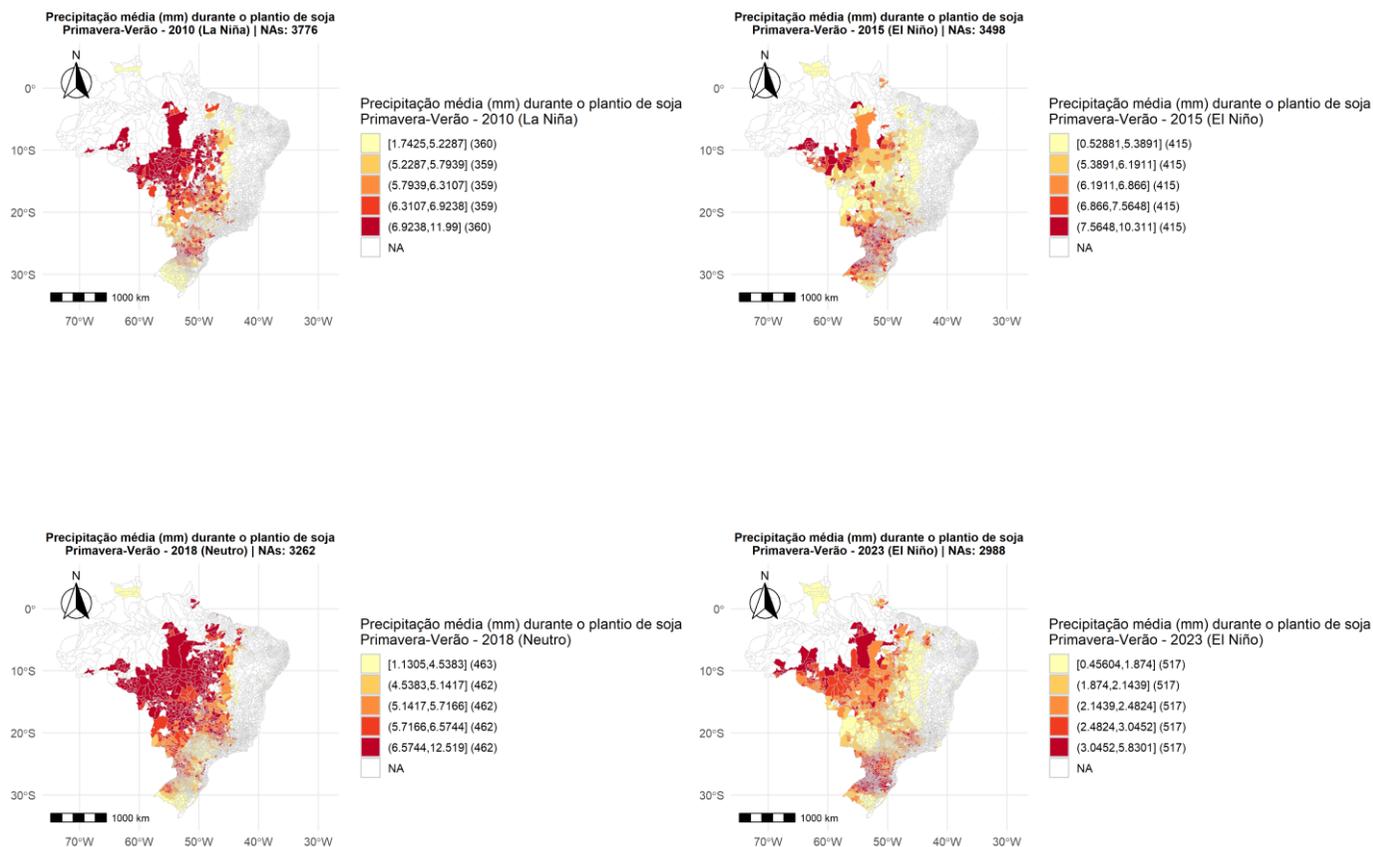
Fonte: Elaboração própria a partir da base de dados da pesquisa.

Figura 4 - Mapas de temperatura média (em °C) para os municípios produtores de soja no Brasil nos anos destacados



Fonte: Elaboração própria a partir da base de dados da pesquisa.

Figura 5 - Mapas de precipitação média (em mm) para os municípios produtores de soja no Brasil nos anos destacados



Fonte: Elaboração própria a partir da base de dados da pesquisa.

5.2 RESULTADOS DA ESTIMAÇÃO DA FUNÇÃO DE PRODUÇÃO

Esta seção apresenta os resultados da estimação da Equação 5, que é uma função de produção Cobb-Douglas modificada para incluir variáveis climáticas. A partir da estrutura de dados em painel, essa função pode ser representada por alguns modelos, por exemplo, *Pooled*, Efeitos Aleatórios (EA) e Efeitos Fixos (EF). É de se esperar que heterogeneidades não observadas dos municípios e que a estrutura produtiva ao longo do tempo exerça alguma influência na produção de soja. Nesse sentido, o modelo mais adequado a ser estimado é o de EF. Para confirmar a adequabilidade desse modelo aos dados deste estudo realizou-se testes estatísticos a fim de escolher o melhor modelo e os resultados desses testes estão na Tabela A.2 (apêndice).

Ao comparar os modelos *Pooled* e EA, o teste de Breusch-Pagan rejeitou a hipótese nula de que a variância dos erros é constante, indicando a presença de heterocedasticidade. Com isso, o modelo de EA é preferível ao modelo *Pooled*. Por sua vez, ao comparar os modelos EA e EF, o teste de Hausman rejeitou a hipótese nula de que as diferenças entre os estimadores dos modelos de efeitos fixos e aleatórios são estatisticamente insignificantes. Isso sugere que o modelo de EF é mais apropriado. Assim, a Equação 5 foi estimada utilizando o modelo de EF pelo método de estimação *within*.

Como já explicado no capítulo de metodologia, algumas variáveis explicativas estão em logaritmo, enquanto outras foram incluídas em nível e em sua forma quadrática. Neste capítulo, são exploradas a direção e a magnitude dos efeitos dessas variáveis sobre a produção de soja, com destaque para o efeito marginal das variáveis transformadas em logaritmo. A Tabela 3 mostra que, entre todos os cenários simulados (*Total*, *El Niño* e *La Niña*), apenas três variáveis apresentaram significância estatística em todos cenários propostos: área plantada, temperatura de plantio e o termo quadrático da precipitação durante o plantio. Outras variáveis climáticas - como temperatura de colheita (e seu quadrado) e umidade relativa - não foram estatisticamente significativas em nenhum dos cenários, o que sugere uma influência menos robusta sobre a produção agregada, ao menos na escala de análise adotada.

Especificamente em relação à área plantada, foi observada uma relação positiva e estatisticamente significativa com a produção de soja. Os resultados indicam que um aumento de 1% na área plantada, mantendo constantes as demais variáveis, gera um acréscimo estimado de 1,03% na produção, evidenciando a presença de retornos constantes à escala no uso do fator terra. Esses achados se alinham aos padrões observados no Brasil, onde a média da área plantada de soja permaneceu estável ou até mesmo cresceu durante os anos de *El Niño* e *La*

Niña, sugerindo uma relativa resiliência do setor frente às oscilações climáticas (Da Silva et al. 2021).

Quando esses resultados são contextualizados à luz de cenários futuros simulados por Pellegrino, Assad e Marin (2007), alguns pontos são relevantes. Os autores estimam que, em cenários de aumento de temperatura e redução de chuvas - como os observados nos anos de *El Niño* - a área apta ao cultivo de soja pode sofrer retrações de até 39%, com perdas concentradas em regiões chave como o Sul e o Nordeste. Ou seja, embora os resultados atuais indiquem ganhos proporcionais de produção com a expansão da área plantada, os limites climáticos à disponibilidade de terras aptas no longo prazo impõem riscos concretos à sustentabilidade desse crescimento.

Além disso, a presença das variáveis climáticas, além de explicar o comportamento da produção do grão, também desempenham papel de variáveis de controle da possível correlação das variáveis omitidas (neste caso, os fatores capital, trabalho e tecnologia) com a variável dependente.

Tabela 3 – Estimativas da função de produção ampliada para o modelo de Efeitos Fixos

Variáveis	Total	<i>El Niño</i>	<i>La Niña</i>
Ln (Área plantada)	1.025*** (0.00769)	1.032*** (0.0135)	1.037*** (0.0119)
Temperatura plantio	-0.752** (0.311)	-1.361* (0.660)	-1.224*** (0.302)
(Temperatura plantio) ²	0.0104* (0.00592)	0.0204 (0.0141)	0.0192*** (0.00607)
Temperatura colheita	-0.0373 (0.259)	-0.313 (0.523)	0.145 (0.273)
(Temperatura colheita) ²	0.000658 (0.00580)	0.00351 (0.0103)	-0.00335 (0.00650)
Precipitação plantio	0.0337 (0.0227)	-0.211** (0.0768)	0.191** (0.0753)
(Precipitação plantio) ²	-0.00444** (0.00176)	0.0126** (0.00512)	-0.0164** (0.00584)
Precipitação colheita	-0.129** (0.0601)	0.0321 (0.0386)	-0.0680 (0.0449)
(Precipitação colheita) ²	0.0178*** (0.00584)	0.00121 (0.00356)	0.00101 (0.00629)
Umidade	0.683 (0.423)	0.00882 (0.437)	0.571 (0.401)
(Umidade) ²	-0.0201* (0.0112)	-0.00426 (0.0117)	-0.0182* (0.0103)
Ln (Radiação solar)	1.171 (0.970)	0.236 (0.962)	2.107* (1.183)
Ln (Velocidade do vento)	-0.135	0.629***	-0.473***

	(0.0822)	(0.220)	(0.119)
Ln (Evaporação)	0.422*	0.604*	0.340
	(0.218)	(0.295)	(0.343)
Constante	-5.566	30.66*	-16.28
	(13.87)	(15.70)	(20.26)
Observações	30,471	6,752	13,030
R ²	0.985	0.993	0.983
R ² ajustado	0.984	0.989	0.979
R ² (<i>Within</i>)	0.984	0.989	0.979
Estatística F	11934	7336	12759
Prob > F	0	0	0
Efeito fixo de ano	Sim	Sim	Sim
Efeito fixo de município	Sim	Sim	Sim

Fonte: Elaboração própria.

Nota: Erros-padrão robustos entre parênteses, com cluster por estado.

*** p<0.01, ** p<0.05, * p<0.1

A Tabela 3 apresenta os coeficientes estimados para a temperatura média de plantio, que são negativos sobre a produção de soja, sendo acentuado nos anos de *El Niño*. Esses resultados corroboram as observações de Schlenker e Roberts (2009), que demonstram a sensibilidade da soja ao aumento de temperatura. As estimativas obtidas para a temperatura média durante o período de colheita não se mostraram estatisticamente significativas em nenhum dos modelos. Estudos experimentais revelam que produtividade e massa de grãos declinam significativamente com o atraso da colheita, especialmente em ambientes com altas temperaturas antes da colheita, reforçando que o período crítico para impactos térmicos na produção de grãos em geral se concentra no pré colheita (Tsukahara et al., 2016).

A mudança no sinal da variável precipitação durante o plantio entre os anos de *El Niño* e *La Niña* reflete os distintos padrões climáticos associados a cada fase do fenômeno. Durante o *El Niño*, a redução e a má distribuição das chuvas em regiões produtivamente importantes comprometem o início do ciclo da soja, o que explica em parte o efeito negativo e significativo observado. Já nos anos de *La Niña*, a maior regularidade das chuvas tende a favorecer o desenvolvimento inicial das lavouras, resultando em um impacto positivo sobre a produção. Esses resultados estão alinhados às evidências empíricas, que destacam o aumento do risco climático em áreas como o Centro-Oeste e o Nordeste diante da intensificação das mudanças climáticas e eventos do ENOS (Araujo, 2012).

Ainda de acordo com a Tabela 3, os termos quadráticos da precipitação média de plantio e da umidade relativa revelam efeitos não lineares sobre a produção de soja. No modelo Total e durante anos de *La Niña*, o coeficiente quadrático da precipitação é negativo e significativo a 5%, indicando que volumes excessivos de chuva, especialmente no início do ciclo produtivo,

podem comprometer a produção (Farias et al., 2007). Já em anos de *El Niño*, o sinal positivo e significativo sugere que aumentos pontuais de precipitação podem amenizar os efeitos da seca. De forma semelhante, o termo quadrático da umidade foi negativo e significativo a 10% no modelo Total e em anos de *La Niña*, sugerindo que níveis elevados de umidade, sobretudo na pré-colheita, podem afetar negativamente a cultura.

Esses achados estão em consonância com Farias et al. (2007), que destacam a alta sensibilidade da soja à disponibilidade de água, especialmente em fases críticas como a floração e o enchimento de grãos. Tal interpretação é reforçada por Tsukahara et al. (2016), que apontam que a combinação de umidade excessiva, chuvas frequentes e temperaturas elevadas compromete a qualidade fisiológica dos grãos e, conseqüentemente, os níveis de produtividade. Portanto, os impactos do ENOS sobre a soja não se restringem apenas à alteração do regime hídrico, mas também à intensificação de condições atmosféricas que favorecem perdas de rendimento quando associadas à umidade elevada.

As estimativas revelam que variáveis climáticas em logaritmo natural exerceram efeitos distintos sobre a produtividade da soja, especialmente em cenários do ENOS. A radiação solar foi positiva e significativa apenas em anos de *La Niña*: um aumento de 1% nessa variável elevou a produção em 2,11%, evidenciando o papel central da insolação nesse contexto. A velocidade do vento apresentou impacto positivo durante *El Niño* (0,63%) e negativo durante *La Niña* (-0,47%), sugerindo que sua intensidade e frequência influenciam de maneira não linear a cultura. Já a evaporação teve efeito positivo e significativo no modelo Total (0,42%) e em anos de *El Niño* (0,61%), indicando que, em condições de equilíbrio hídrico, essa variável pode sinalizar atmosferas mais favoráveis ao crescimento da soja.

Segundo apontamentos de Câmara (2000), a radiação solar é determinante para a fotossíntese e formação de grãos, desde que as condições hídricas e nutricionais sejam adequadas. A nebulosidade, por sua vez, limita a radiação incidente, especialmente em anos de *El Niño* (De Aguiar Monteiro et al., 2021). Ademais, durante eventos de *La Niña*, a menor cobertura de nuvens pode favorecer o aumento da radiação e, conseqüentemente, do rendimento. Quanto à velocidade do vento, Monteiro (2009) observa que sua ação moderada pode ser benéfica ao facilitar a circulação de ar e evitar doenças, mas, como alertam Crespo et al. (2024), quando excessiva, pode elevar a evapotranspiração e induzir perdas fisiológicas à lavoura.

O padrão de precipitação durante a *La Niña* pode variar entre excesso e déficit hídrico de acordo com a região e, de maneira geral, tende a ocasionar aumento da radiação solar e da demanda evaporativa atmosférica, com ventos mais intensos, elevando o estresse hídrico e

mecânico sobre as plantas, impactando negativamente a produção de soja (Gazzoni, 1974; Monteiro, 2009; Crespo et al., 2024).

De forma geral, os resultados obtidos evidenciam que os fenômenos ENOS exercem influência diferenciada sobre a produção da soja no Brasil. Em anos *de El Niño*, observam-se impactos adversos mais pronunciados, principalmente nas variáveis climáticas durante o plantio (Araujo, 2012). A precipitação média de plantio, por exemplo, apresentou efeito negativo enquanto seu termo quadrático teve sinal positivo, sugerindo uma relação não linear em que níveis intermediários de chuva podem ser menos prejudiciais do que extremos. Além disso, os efeitos da temperatura de plantio também foram negativos nesse cenário, refletindo o estresse térmico associado à anomalia quente do Pacífico (Schlenker; Roberts, 2009).

Na próxima sessão, serão apresentadas as mudanças percentuais projetadas de nível de produção diante das alterações nas variáveis de temperatura e precipitação nos três cenários (Total, *El Niño* e *La Niña*) estimados no presente estudo.

5.3 EFEITOS DA TEMPERATURA E PRECIPITAÇÃO SOBRE A PRODUÇÃO DE SOJA

Esta seção apresenta as variações percentuais⁵ no nível de produção da soja frente às mudanças de temperatura média e precipitação média de plantio, que foram significativas, exceto esta última no modelo Total, como mostrado na Tabela 4. A escolha por analisar com mais detalhes essas variáveis se dá pela sua importância na etapa de desenvolvimento da soja, que é a que mais afeta a produtividade do grão, seguindo os apontamentos de Farias et al. (2007) e Neumaier et al. (2020). Aqui serão abordados os cenários de aumento de 0,5, 1 e 1,5 nas variáveis em nível, conforme pode ser visto na Tabela 4.

A análise da tabela evidencia os impactos marginais da variação nos níveis de temperatura e precipitação durante o período de plantio sobre a produção de soja, conforme os diferentes estados do fenômeno ENOS. Observou-se que o aumento da temperatura média no momento do plantio exerce um efeito negativo expressivo sobre a produção da cultura, sendo esse impacto acentuado sob cenários de ENOS (Schlenker; Roberts, 2009; Neto; Artiaga, 2023; Luiz; Silva, 2024).

Para um acréscimo de 1,5 °C na temperatura média, estima-se uma redução de 67,63% na produção no modelo geral, sendo as quedas mais elevadas nos anos de *El Niño* (-87,02%) e

⁵ Os coeficientes estimados dessas variáveis, dispostos na Tabela 1, são transformados em variações percentuais conforme a seguinte fórmula: $(\exp^{\beta * \text{Variação desejada em nível}} - 1) * 100$.

La Niña (-84,05%). Tais resultados evidenciam a vulnerabilidade do sistema produtivo da soja ao estresse térmico durante as fases iniciais de desenvolvimento da planta. (Berlato; Fontana; Gonçalves, 1992; Farias; Nepomuceno; Neumaier, 2007; Araujo, 2012; Cirino et al., 2015; Neumaier et al., 2020).

Os cenários simulados de variação térmica durante o plantio reforçam os efeitos não lineares do clima sobre a agricultura, conforme identificam Schlenker e Roberts (2009), ao demonstrar que pequenos aumentos de temperatura já são suficientes para causar declínios na produtividade.

A soja, por ser uma cultura adaptada a faixas térmicas restritas, apresenta sensibilidade a desvios de temperatura, sobretudo quando esses ocorrem no início do ciclo fenológico. Essa sensibilidade foi igualmente identificada por Tirfi e Oyekale (2022) e Li (2023), cujos estudos em contextos africanos e asiáticos mostraram que aumentos contínuos de temperatura reduzem a produtividade agrícola, deslocando o cultivo para fora de suas zonas fisiológicas ideais e implicando perdas mesmo quando controlados os efeitos de solo, tecnologia e manejo.

No contexto do ENOS, os impactos térmicos sobre a cultura da soja não se manifestam de maneira uniforme, sendo modulados pelas características específicas de cada fase do fenômeno. Durante episódios de *El Niño*, as temperaturas mais elevadas em regiões como o Centro-Oeste e Sudeste tendem a antecipar o ciclo da soja, encurtando o período de enchimento de grãos e, conseqüentemente, reduzindo a produtividade, como apontam Araujo (2012) e Sentelhas et al. (2015).

A variabilidade nos padrões de precipitação provocada pelo fenômeno ENOS exerce influência direta sobre o rendimento da soja nas principais regiões produtoras do Brasil. Os eventos de *El Niño* tendem a provocar redução nos volumes pluviométricos no Nordeste brasileiro e excesso de chuvas na região Sul, em linha com o que Berlato e Fontana (2003), Araujo (2012) e Cirino et al. (2015) verificam. Por outro lado, durante episódios de *La Niña*, a literatura científica observa uma configuração oposta, com maior propensão à estiagem no Sul e precipitações mais regulares ou intensas nas demais regiões.

Os resultados da simulação corroboram quanto aos efeitos das mudanças nos níveis de precipitação: em anos de *El Niño*, um aumento de 1 mm na precipitação média durante o plantio resultou em queda de 19,02% na produção de soja, sugerindo impactos negativos do excesso de chuva nesse período.

A relação entre a fase de *El Niño* e a produtividade de soja foi analisada por Araujo (2012) e, para o autor, o estado do Rio Grande do Sul (RS) é um exemplo de estado que

demonstrou propensão a ter a produção do grão inviabilizada devido às ocorrências de eventos extremos.

Enquanto isso, nos anos de *La Niña*, o mesmo aumento na precipitação resultou em crescimento de 21,05% na produção, evidenciando que, sob condições normalmente mais secas, esse aporte adicional de água favorece o desenvolvimento inicial da lavoura, em linha com os achados de Araujo (2012) e Cirino et al. (2015), que destacam a importância da distribuição adequada das chuvas na produção da soja. Esses achados reforçam que o impacto da precipitação sobre a soja é mediado pelas condições climáticas sazonais, sendo o entendimento da dinâmica do ENOS essencial para estratégias de manejo climático e adaptação da agricultura.

Tabela 4 – Variação (%) na produção de soja sob cenários de aumento de temperatura e precipitação

Evento ENOS	Variação em nível na temperatura de plantio (°C)	Variação na produção da soja (%)	Variação em nível na precipitação de plantio (mm)	Variação na produção da soja (%)
Total	+1	-52,86	+1	–
<i>El Niño</i>	+1	-74,36	+1	-19,02
<i>La Niña</i>	+1	-70,6	+1	21,05
Total	+0,5	-31,34	+0,5	–
<i>El Niño</i>	+0,5	-49,37	+0,5	-10,01
<i>La Niña</i>	+0,5	-45,77	+0,5	10,02
Total	+1,5	-67,63	+1,5	–
<i>El Niño</i>	+1,5	-87,02	+1,5	-27,13
<i>La Niña</i>	+1,5	-84,05	+1,5	33,18

Fonte: Elaboração própria.

Nota: O símbolo “–” na última coluna indica que não houve o cálculo de variação, pois o coeficiente foi não significativo, nem mesmo a 10%.

5.4 COMPARAÇÃO ENTRE VARIAÇÃO DE TEMPERATURA NA PRODUÇÃO DE SOJA EM DIFERENTES PERÍODOS

Para fins comparativos, a Tabela A3 (Apêndice) apresenta resultados da variação de temperatura durante o período de crescimento da soja, avaliando os impactos na produção de soja no Brasil considerando os eventos de *El Niño*, *La Niña* e o cenário agregado (Total). Enquanto no presente trabalho a análise foi conduzida a partir da variação conjunta da temperatura e da precipitação no período de plantio, no intervalo de 2010 a 2023, o estudo complementar concentrou-se exclusivamente no efeito do aumento da temperatura durante o ciclo de crescimento da soja, abrangendo o período de 2016 a

2023. Os resultados obtidos em ambos trabalhos apontam para perdas acentuadas na produção, especialmente durante anos de *El Niño*.

No presente estudo, por exemplo, um aumento de 1°C no período de plantio reduziu a produção em 52,86% no cenário total, chegando a 74,36% em anos de *El Niño* e 70,60% em *La Niña* (Tabela 4). Já no estudo comparativo, um aumento da mesma magnitude resultou em perdas de 9,45% no período total, 51,52% em *El Niño* e 22,35% em *La Niña* (Tabela A3). A diferença de magnitude entre os resultados pode ser explicada tanto pelas variáveis consideradas em cada modelo quanto pelo horizonte temporal analisado. Como é possível observar, o aumento de 1,5 °C em cenário de *El Niño* resultaria em uma redução de 66,24% na produção de soja no período de 2016 a 2023, enquanto o mesmo aumento causaria uma redução de 87,02% no período de 2010 a 2023, indicando que o aumento de temperatura afeta de maneira distinta conforme o horizonte analisado. Os resultados evidenciam que os efeitos negativos da elevação da temperatura tornam-se mais pronunciados quando considerados em um horizonte temporal mais longo, no qual a acumulação dos impactos climáticos sobre o cultivo da soja se intensifica.

De um lado, a presente análise incluiu simultaneamente a variação da temperatura e da precipitação no período de plantio, refletindo de forma mais direta as condições do cultivo, além de abranger uma série temporal mais extensa (2010-2023). De outro lado, o estudo comparativo avaliou apenas a temperatura no ciclo de crescimento da soja em um período mais curto (2016-2023), capturando de forma mais isolada esse efeito. No geral, ambos resultados convergem ao indicar que as perdas de produção são mais intensas em anos de *El Niño*, seguidas por *La Niña*, reforçando a importância de compreender a interação entre as mudanças climáticas e a abrangência espacial e temporal de seus efeitos na produção de soja.

6 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo compreender as relações entre variáveis climáticas e a produção de soja no Brasil, à luz das transformações ambientais e econômicas que afetam diretamente o setor agrícola. A partir da fundamentação teórica apresentada nos capítulos iniciais, foi possível construir uma base sólida de conhecimentos sobre a ecofisiologia da soja, bem como sobre sua relevância estratégica para a economia nacional. A análise demonstrou como fatores climáticos, como temperatura e precipitação, interagem com os processos fisiológicos da planta, impactando diretamente seu desempenho produtivo.

Além da abordagem fisiológica, foram discutidas as dimensões econômicas da cultura da soja, evidenciando sua importância para o Produto Interno Bruto (PIB) do país e sua expressiva participação na geração de empregos. Os dados analisados sobre área plantada, produtividade e volume de produção ao longo de diferentes períodos permitiram identificar tendências e padrões regionais, os quais foram sintetizados por meio de representações gráficas, como o mapa de calor construído para os anos de 2010, 2015, 2018 e 2023. Essa abordagem reforçou a relevância da soja não apenas como commodity agrícola, mas também como componente estratégico do desenvolvimento socioeconômico brasileiro.

Ademais, a análise foi ampliada para a discussão sobre as mudanças climáticas globais e seus desdobramentos na agricultura. Foram apresentados estudos que abordam eventos climáticos e o fenômeno *El Niño*-Oscilação Sul (ENOS), contextualizando seus efeitos específicos sobre a produção agrícola mundial e brasileira.

Ficou evidente que tais eventos interferem nos rendimentos das lavouras de soja, podendo acarretar perdas ou ganhos sazonais, dependendo da região e da fase do ciclo da cultura. Tais evidências reafirmam a urgência de políticas públicas voltadas à mitigação de riscos climáticos e à adaptação dos sistemas produtivos.

A principal contribuição deste estudo está apresentada no capítulo metodológico, onde foi detalhado o uso de dados em painel e a formulação de modelos teóricos e empíricos capazes de captar a influência das variáveis climáticas sobre a produção da soja. A utilização desse tipo de abordagem estatística, pouco explorada de forma integrada à climatologia e economia agrícola, representa um avanço para os estudos da área.

A aplicação da metodologia permitiu não apenas quantificar as relações entre clima e produção, como também realizar simulações considerando diferentes condições do ENOS, o que oferece suporte analítico a gestores públicos e produtores rurais na tomada de decisão.

Por fim, os resultados empíricos obtidos evidenciaram relações consistentes entre as variáveis climáticas e a produção da soja em contextos distintos de neutralidade climática, *El Niño* e *La Niña*. As regressões e simulações realizadas apontaram para efeitos heterogêneos, reforçando a necessidade de estratégias regionalizadas para enfrentamento dos impactos das mudanças climáticas. Espera-se que este estudo contribua com a literatura acadêmica ao oferecer uma análise robusta e atualizada, e que sirva como base para investigações futuras que aprofundem o entendimento das interações entre clima, agricultura e economia.

REFERÊNCIAS

- ADAMS, Richard M. et al. **Effects of global climate change on agriculture: an interpretative review.** *Climate research*, v. 11, n. 1, p. 19-30, 1998.
- ALBERTO, Cleber Maus et al. **Água no solo e rendimento do trigo, soja e milho associados ao El Niño Oscilação Sul.** *Pesquisa Agropecuária Brasileira*, v. 41, p. 1067-1075, 2006.
- ARAGÓN, Fernando M. ; OTEIZA, Francisco; RUD, Juan Pablo. **Climate change and agriculture: Subsistence farmers' response to extreme heat.** *American Economic Journal: Economic Policy*, v. 13, n. 1, p. 1-35, 2021.
- ARAUJO, Paulo Henrique Cirino. **Eventos climáticos extremos: os efeitos dos fenômenos El Niño e La Niña sobre a produtividade agrícola das regiões nordeste e Sul do Brasil.** 2012.
- ASSUNÇÃO, Juliano J. **Rural organization and land reform in Brazil: the role of nonagricultural benefits of landholding.** *Economic Development and Cultural Change*, v. 56, n. 4, p. 851-870, 2008.
- ASSUNÇÃO, Juliano; CHEIN, Flávia. **Climate change and agricultural productivity in Brazil: future perspectives.** *Environment and Development Economics*, v. 21, n. 5, p. 581-602, 2016.
- BENOIT, Kenneth. **Linear regression models with logarithmic transformations.** *London School of Economics, London*, v. 22, n. 1, p. 23-36, 2011.
- BERLATO, M. A.; MATZENAUER, R.; BERGAMASCHI, H. **Evapotranspiração máxima da soja e relações com a evapotranspiração calculada pela equação de Penman, evaporação do tanque “classe A” e radiação solar global.** *Agronomia Sulriograndense*, v. 22, n. 2, p. 251-259, 1986.
- BERLATO, Moacir A. FONTANA, Denise Cybis; GONÇALVES, Hélio M. **Relação entre o rendimento de grãos da soja e variáveis meteorológicas.** *Pesquisa Agropecuária Brasileira*, p. 695-702, 1992.
- BOARD, James E.; KAHLON, Charanjit S. **Soybean yield formation: what controls it and how it can be improved.** *Soybean physiology and biochemistry*, p. 1-36, 2011.
- BORTHWICK, H. A.; PARKER, M. W. **Photoperiodic responses of several varieties of soybeans.** *Botanical Gazette*, v. 101, n. 2, p. 341-365, 1939.
- CÂMARA, Gil Miguel de Sousa; HEIFFIG, Lília Sichmann. **Fisiologia, ambiente e rendimento da cultura da soja.** *Soja: tecnologia da produção II*, 2000.
- CAMERON, A. C.; TRIVEDI, P. K. **Microeconometrics: methods and applications.** Cambridge: Cambridge University Press, 2005.
- CARR, Tony W. et al. **Climate change impacts and adaptation strategies for crops in West Africa: a systematic review.** *Environmental research letters*, v. 17, n. 5, p. 053001, 2022.

- CEPEA – CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA; ABIOVE – ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DE ÓLEOS VEGETAIS. **Cadeia da soja e do biodiesel representou 27% do PIB do agronegócio e gerou 2 milhões de empregos em 2022.** Cepea, 2023. Disponível em: <https://www.cepea.org.br/br/releases/cepea-abiove-cadeia-da-soja-e-do-biodiesel-representou-27-do-pib-do-agronegocio-e-gerou-2-milhoes-de-empregos-em-2022.aspx>. Acesso em: 16 jul. 2025.
- CENTRO DE PREVISÃO DE TEMPO E ESTUDOS CLIMÁTICOS – CPTEC/INPE. **El Niño e La Niña – ENOS.** Disponível em: <http://enos.cptec.inpe.br/>. Acesso em: 25 ago. 2025.
- CHAMBERS, R. G. **Applied Production Analysis: A Dual Approach.** [s.l.] Cambridge University Press, 1988.
- CIRINO, Paulo Henrique et al. **Assessing the impacts of ENSO-related weather effects on the Brazilian agriculture.** *Procedia Economics and Finance*, v. 24, p. 146-155, 2015.
- CLIMATE PREDICTION CENTER – CPC. **Climate Prediction Center.** 2023. Disponível em: <https://www.cpc.ncep.noaa.gov/>. Acesso em: 25 ago. 2025.
- CONSENSUS CDS PROJECT – CCDS. **Consensus Coding Sequence (CCDS) Project.** 2023. Disponível em: <https://www.ncbi.nlm.nih.gov/CCDS/>. Acesso em: 25 ago. 2025.
- Companhia Nacional de Abastecimento (CONAB), 2019 - **Calendário Agrícola (plantio e colheita).** Disponível em: <https://www.gov.br/conab/pt-br/acao-a-informacao/institucional/publicacoes/outras-publicacoes/calendario-agricola-plantio-e-colheita>. Acesso em: 6 ago. 2025.
- Companhia Nacional de Abastecimento (CONAB), 2022. **Série histórica de safras de grãos.** Brasília, 2025. Disponível em: <https://portaldeinformacoes.conab.gov.br/safra-serie-historica-graos.html>. Acesso em: 16 jul. 2025.
- COSTA, N. P. et al. **Zoneamento ecologico do estado do Parana para a producao de sementes de cultivares precoces de soja.** 1992.
- DA SILVA, Evandro Henrique Figueiredo Moura et al. **Impact assessment of soybean yield and water productivity in Brazil due to climate change.** *European Journal of Agronomy*, v. 129, p. 126329, 2021.
- DE SOUZA FERREIRA FILHO, Joaquim Bento; DE MORAES, Gustavo Inacio. **Climate change, agriculture and economic effects on different regions of Brazil.** *Environment and Development Economics*, v. 20, n. 1, p. 37-56, 2015.
- DESCHÊNES, Olivier; GREENSTONE, Michael. **The economic impacts of climate change: evidence from agricultural output and random fluctuations in weather.** *American economic review*, v. 97, n. 1, p. 354-385, 2007.

- DOMINGUES, Edson Paulo; MAGALHÃES, Aline Souza; RUIZ, Ricardo Machado. **Cenários de mudanças climáticas e agricultura no Brasil: impactos econômicos na região Nordeste.** Revista Econômica do Nordeste, v. 42, n. 2, p. 229-246, 2011.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Soja: dados econômicos.** Brasília, DF: Embrapa, 2025. Disponível em: <https://www.embrapa.br/web/portal/soja/cultivos/soja1/dados-economicos>. Acesso em: 25 ago. 2025.
- ECMWF - European Centre for Medium-Range Weather Forecasts. **ERA5: data documentation.** Disponível em: <https://confluence.ecmwf.int/display/CKB/ERA5%3A+data+documentation>. Acesso em: 13 jan. 2025.
- FAGAN, Evandro Binotto et al. **Fisiologia da fixação do nitrogênio em soja: uma revisão.** Revista da faculdade de zootecnia, veterinária e agronomia, v. 14, p. 89-106, 2007.
- FAO, **OECD-FAO Agricultural Outlook 2025-2034**, OECD Publishing, Paris/FAO, Rome, 2025. <https://doi.org/10.1787/601276cd-en>.
- FARIAS, José Renato B.; NEPOMUCENO, Alexandre L.; NEUMAIER, Norman. **Ecofisiologia da soja.** Embrapa Soja. Circular técnica, v. 48, 2007.
- FEHR, Walter; CAVINESS, Charles. **Stages of soybean development.** 1977.
- FERES, Jose Gustavo; REIS, Eustaquio Jose; SPERANZA, Juliana Simoes. **Assessing the impact of climate change on the Brazilian agricultural sector.** 2008.
- FREITAS, Rogério Edivaldo; MENDONÇA, Marco Aurélio Alves de. **Expansão agrícola no Brasil ea participação da soja: 20 anos.** Revista de Economia e Sociologia Rural, v. 54, n. 3, p. 497-516, 2016.
- GAZZONI, Décio Luiz. **Avaliação do efeito de três níveis de desfolhamento aplicados em quatro estádios de crescimento de dois cultivares de soja (Glycine max (L.) Merrill) sobre a produção ea qualidade do grão.** UFRGS, 1974.
- GRIGORIEVA, Elena; LIVENETS, Alexandra; STELMAKH, Elena. **Adaptation of agriculture to climate change: A scoping review.** Climate, v. 11, n. 10, p. 202, 2023.
- GUIMARÃES, Daniel P.; REIS, Ruiبران dos. **Impactos do Fenômeno Enos Sobre a Temperatura no Brasil.** Revista Espinhaço, 2 dez. 2012.
- GUJARATI, Damodar N.; PORTER, Dawn C. **Basic econometrics.** McGraw-hill, 2009.
- GUJARATI, D. N.; PORTER, D. C. **Econometria básica.** 5. ed. Porto Alegre: AMGH, 2011.
- INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Ipeadata: banco de dados macroeconômicos, financeiros e regionais.** 2025. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 25 ago. 2025.

- INSTITUTO NACIONAL DE METEOROLOGIA - INMET. **Inmet.gov.br**. Disponível em: <<https://portal.inmet.gov.br/>>. Acesso em: 6 ago. 2025.
- IPCC. **Synthesis report. Climate Change 2007. Working Groups I, II and III to the Fourth Assessment**, 2008.
- IPCC - **AR6 Climate Change 2022: Impacts, Adaptation and Vulnerability** —. Ipcc.ch. Disponível em: <<https://www.ipcc.ch/report/sixth-assessment-report-working-group-ii/>>. Acesso em: 6 ago. 2025.
- JIANG, Chuang-Dao et al. **Leaf orientation, photorespiration and xanthophyll cycle protect young soybean leaves against high irradiance in field**. *Environmental and Experimental Botany*, v. 55, n. 1-2, p. 87-96, 2006.
- JUSTINO, Flávio et al. **Mean and interannual variability of maize and soybean in Brazil under global warming conditions**. *American Journal of Climate Change*, v. 2, n. 4, p. 237-253, 2013.
- LI, C. **Climate change impacts on rice production in Japan: A Cobb-Douglas and panel data analysis**. *Ecological Indicators*, v. 147, p. 110008, 1 mar. 2023.
- LUIZ, Alfredo José Barreto; DA SILVA, Fernando Antonio Macena. **Efeito do El Niño Oscilação Sul na produtividade da soja em Planaltina, DF**. *Agrometeoros*, v. 32, 2024.
- MATHEW, Jomol P. et al. **Differential response of soybean yield components to the timing of light enrichment**. *Agronomy Journal*, v. 92, n. 6, p. 1156-1161, 2000.
- MENDELSON, Robert; NORDHAUS, William D.; SHAW, Daigee. **The impact of global warming on agriculture: a Ricardian analysis**. *The American economic review*, p. 753-771, 1994.
- MENDELSON, Robert; DINAR, Ariel; SANGHI, Apurva. **The effect of development on the climate sensitivity of agriculture**. *Environment and Development Economics*, v. 6, n. 1, p. 85-101, 2001.
- MONTEIRO, J. E. B. A. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Brasília: INMET, 2009. Disponível em https://portal.inmet.gov.br/uploads/publicacoesDigitais/agrometeorologia_dos_cultivos.pdf. Acesso em 17 de julho de 2025.
- NETO, Nicolau; ARTIAGA, Publius Lentulus. **Produtividade de soja in sílico no bioma Cerrado em função do fenômeno El Niño Oscilação Sul**. 2023.
- NEUMAIER, Norman; RENATO, José; FARIAS, Bouças; et al. **Estádios fenológicos da soja Ecofisiologia da soja**. [s.l.: s.n., s.d.]. Disponível em: <<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1128387/1/p.-33-54-de-SP-17-2020-online.pdf>>.

- PARRÉ, José Luiz; CHAGAS, André Luis Squarize; ARENDS-KUENNING, Mary Paula. **The effect of farm size and farmland use on agricultural diversification: a spatial analysis of Brazilian municipalities.** *Agricultural and Food Economics*, v. 12, n. 1, p. 27, 2024.
- PELLEGRINO, Giampaolo Queiroz; ASSAD, Eduardo Delgado; MARIN, Fábio Ricardo. **Mudanças climáticas globais ea agricultura no Brasil.** *Revista Multiciência*, v. 8, n. 1, p. 139-162, 2007.
- Portal de Informações Agropecuárias.** Conab.gov.br. Disponível em: <<https://portaldeinformacoes.conab.gov.br/produtos-360.html>>. Acesso em: 6 ago. 2025.
- PURCELL, Larry C. ; SALMERON, Montserrat; ASHLOCK, Lanny. **Soybean growth and development.** *Arkansas soybean production handbook*, v. 197, p. 1-8, 2014.
- REZAEI, Ehsan Eyshi et al. **Climate change impacts on crop yields.** *nature reviews earth & environment*, v. 4, n. 12, p. 831-846, 2023.
- ROSENZWEIG, Cynthia; PARRY, Martin L. **Potential impact of climate change on world food supply.** *Nature*, v. 367, n. 6459, p. 133-138, 1994.
- SANGHI, Apurva et al. **Global warming impacts on Brazilian agriculture: estimates of the Ricardian model.** *Economía aplicada*, v. 1, n. 1, p. 7-33, 1997.
- SANGHI, Apurva; MENDELSON, Robert. **The impacts of global warming on farmers in Brazil and India.** *Global Environmental Change*, v. 18, n. 4, p. 655-665, 2008.
- SCHLENKER, Wolfram; ROBERTS, Michael. **Nonlinear effects of weather on crop yields: implications for climate change.** *Review of Agricultural Economics*, v. 28, 2006.
- SCHLENKER, Wolfram; ROBERTS, Michael J. **Nonlinear temperature effects indicate severe damages to US crop yields under climate change.** *Proceedings of the National Academy of sciences*, v. 106, n. 37, p. 15594-15598, 2009.
- SEO, S. Niggol; MENDELSON, Robert. **A Ricardian analysis of the impact of climate change on South American farms.** 2008.
- SILVA, Daniel S. et al. **Temperature effect on Brazilian soybean yields, and farmers' responses.** *International Journal of Agricultural Sustainability*, v. 21, n. 1, p. 2173370, 2023.
- SILVA, Rodrigo Peixoto da. **The labor market in the soybean and biodiesel production chain in Brazil.** Piracicaba: CEPEA, 2025. Disponível em: <https://www.cepea.esalq.usp.br/en/studies/the-labor-market-in-the-soybean-and-biodiesel-production-chain-in-brazil.aspx>. Acesso em: 25 jun. 2025.
- TIRFI, Abera Gayesa; OYEKALE, Abayomi Samuel. **Impact of climate change on yields of wheat in Ethiopia: An augmented Cobb-Douglas production function approach.** *Journal of Agricultural, Food and Environmental Sciences, JAFES*, v. 76, n. 1, p. 34-47, 2022.

- TSUKAHARA, Rodrigo Yoiti et al. **Produtividade de soja em consequência do atraso da colheita e de condições ambientais.** Pesquisa agropecuária brasileira, v. 51, n. 08, p. 905-915, 2016.
- VARIAN, Hal R. **Intermediate microeconomics: a modern approach.** Elsevier Brasil, 2003.
- VIEIRA FILHO, José Eustáquio Ribeiro. **A cadeia produtiva de soja e o desenvolvimento econômico e regional no Brasil.** Texto para Discussão, 2024.
- WAHUA, T. A. T.; MILLER, D. A. **Effects of Shading on the N₂-Fixation, Yield, and Plant Composition of Field-Grown Soybeans 1.** Agronomy Journal, v. 70, n. 3, p. 387-392, 1978.
- WOOLDRIDGE, J. M. **Econometric analysis of cross section and panel data.** 2. ed. Cambridge: MIT Press, 2010.

APÊNDICE

Tabela A 1–

Ano	IGP-DI (%)	Índice de correção (2010 = 100)
2010	11.30	100
2011	5.00	104.99721
2012	8.10	113.4985
2013	5.52	119.76176
2014	3.78	124.29306
2015	10.70	137.59379
2016	7.18	147.47659
2017	-0.42	146.85935
2018	7.10	157.28542
2019	7.70	169.39
2020	23.08	208.49069
2021	17.74	245.47197
2022	5.03	257.81583
2023	-3.30	249.31748

Fonte: Elaboração própria com base nos dados do IPEADATA (2025).

Tabela A 2– Escolha do melhor modelo de dados em painel com base nos Testes de *Hausman e Breusch-Pagan*

Variáveis	Total			<i>El Niño</i>			<i>La Niña</i>		
	<i>Pooling</i>	Efeitos Aleatórios	Efeitos Fixos	<i>Pooling</i>	Efeitos Aleatórios	Efeitos Fixos	<i>Pooling</i>	Efeitos Aleatórios	Efeitos Fixos
Ln (Área plantada)	1.028*** (0.000977)	1.044*** (0.00145)	1.116*** (0.00307)	1.020*** (0.00158)	1.021*** (0.00181)	1.042*** (0.00634)	1.035*** (0.00171)	1.045*** (0.00206)	1.130*** (0.00531)
Temperatura plantio	-0.315*** (0.0237)	-0.291*** (0.0325)	-0.626*** (0.0493)	-0.582*** (0.0445)	-0.584*** (0.0495)	-0.785*** (0.148)	-0.0301 (0.0411)	0.0337 (0.0492)	-1.154*** (0.111)
(Temperatura plantio) ²	0.00441*** (0.000499)	0.00355*** (0.000682)	0.00918*** (0.00102)	0.00931*** (0.000888)	0.00920*** (0.000993)	0.00815*** (0.00312)	-0.000678 (0.000868)	-0.00185* (0.00104)	0.0199*** (0.00227)
Temperatura colheita	0.205*** (0.00994)	0.225*** (0.0131)	0.422*** (0.0226)	0.316*** (0.0239)	0.326*** (0.0259)	-0.527*** (0.0989)	0.119*** (0.0163)	0.0895*** (0.0191)	0.525*** (0.0513)
(Temperatura colheita) ²	-0.00405*** (0.000207)	-0.00450*** (0.000287)	-0.00957*** (0.000571)	-0.00616*** (0.000482)	-0.00624*** (0.000527)	0.00921*** (0.00218)	-0.00256*** (0.000340)	-0.00225*** (0.000407)	-0.0143*** (0.00117)
Precipitação plantio	0.0164** (0.00722)	0.0181** (0.00770)	0.00157 (0.00836)	-0.162*** (0.0127)	-0.193*** (0.0128)	-0.290*** (0.0169)	0.113*** (0.0123)	0.124*** (0.0128)	0.0970*** (0.0169)
(Precipitação plantio) ²	-0.00506*** (0.000569)	-0.00541*** (0.000599)	-0.00425*** (0.000638)	0.0113*** (0.00108)	0.0133*** (0.00107)	0.0167*** (0.00132)	-0.0141*** (0.000953)	-0.0151*** (0.000992)	-0.0121*** (0.00121)
Precipitação colheita	-0.160*** (0.00679)	-0.208*** (0.00755)	-0.228*** (0.00840)	-0.165*** (0.0135)	-0.161*** (0.0136)	-0.00232 (0.0183)	-0.185*** (0.0120)	-0.227*** (0.0136)	-0.241*** (0.0207)
(Precipitação colheita) ²	0.0178*** (0.000750)	0.0237*** (0.000826)	0.0273*** (0.000906)	0.0200*** (0.00144)	0.0193*** (0.00143)	0.00309* (0.00181)	0.00897*** (0.00142)	0.0105*** (0.00163)	0.00682** (0.00266)
Umidade	-0.0536*** (0.0173)	-0.104*** (0.0224)	-0.0226 (0.0344)	0.191*** (0.0332)	0.178*** (0.0377)	-0.299** (0.140)	-0.401*** (0.0304)	-0.478*** (0.0352)	-0.272*** (0.0744)

(Umidade) ²	0.00214*** (0.000473)	0.00367*** (0.000621)	-0.000308 (0.00101)	-0.00510*** (0.000894)	-0.00480*** (0.00102)	0.00260 (0.00401)	0.0125*** (0.000840)	0.0151*** (0.000973)	0.00368* (0.00223)
Ln (Radiação solar)	-0.350*** (0.0270)	-0.245*** (0.0355)	-0.455*** (0.0567)	-0.459*** (0.0381)	-0.493*** (0.0424)	-0.557*** (0.108)	-0.768*** (0.0614)	-0.706*** (0.0672)	-0.387*** (0.114)
LN (Velocidade do vento)	-0.102*** (0.00735)	-0.193*** (0.0104)	-0.484*** (0.0180)	-0.0262** (0.0113)	-0.0112 (0.0127)	0.531*** (0.0372)	-0.169*** (0.0131)	-0.227*** (0.0155)	-1.066*** (0.0377)
Ln (Evaporação)	0.127*** (0.0271)	0.0628* (0.0354)	0.324*** (0.0549)	0.328*** (0.0399)	0.400*** (0.0438)	0.611*** (0.102)	0.151*** (0.0482)	0.0890 (0.0547)	0.219** (0.0963)
Constante	16.28*** (0.521)	14.68*** (0.710)	20.03*** (1.120)	18.50*** (0.795)	19.19*** (0.900)	42.30*** (3.460)	23.18*** (1.123)	22.38*** (1.265)	28.07*** (2.319)
Observações	30,574	30,574	30,574	7,020	7,020	7,020	13,128	13,128	13,128
R ²	0.975		0.866	0.985		0.929	0.968		0.873
Número de municípios		2,685	2,685		2,628	2,628		2,594	2,594
Teste Breusch e Pagan									
Estatística Chi ²		1530.23			32.89			62.28	
Prob > Chi ²		0.00			0.000			0.000	
Teste de Hausman									
Estatística Chi ²			2057.99			815.75			1985.14
Prob > Chi ²			0.0000			0.0000			0.000

Fonte: Elaboração própria.

Nota: Erros-padrão robustos entre parênteses.

*** p<0.01, ** p<0.05, * p<0.1

Tabela A3 – Variação (%) na produção de soja em cenários de aumento de temperatura entre 2016 e 2023

Fase ENOS	Variação de temperatura na fase de crescimento da soja (°C)	Variação na produção de soja (%)
Total	+1	-9.45
<i>El Niño</i>	+1	-51.52
<i>La Niña</i>	+1	-22.35
Total	+0.5	-4.84
<i>El Niño</i>	+0.5	-30.37
<i>La Niña</i>	+0.5	-11.88
Total	+1.5	-13.84
<i>El Niño</i>	+1.5	-66.24
<i>La Niña</i>	+1.5	-31.58

Fonte: elaboração de Da Silva Pereira, Xavier da Cunha e Faria (2025).