

PONTIFÍCIA UNIVERSIDADE CATÓLICA
DO RIO DE JANEIRO



Monografia de Final de Curso

**IMPACTOS DAS MUDANÇAS CLIMÁTICAS SOBRE A PRODUTIVIDADE
AGRÍCOLA DO BRASIL**

Gabriela El-Jaick Rapozo Leoni Lopes de Oliveira

1810518

Orientador: Márcio Garcia

Co-Orientador: Gustavo Pinto

Rio de Janeiro

Novembro/2021

PONTIFÍCIA UNIVERSIDADE CATÓLICA
DO RIO DE JANEIRO



Monografia de Final de Curso

**IMPACTOS DAS MUDANÇAS CLIMÁTICAS SOBRE A PRODUTIVIDADE
AGRÍCOLA DO BRASIL**

Gabriela El-Jaick Rapozo Leoni Lopes de Oliveira

1810518

Orientador: Márcio Garcia

Co-Orientador: Gustavo Pinto

Declaro que este trabalho é de minha autoria e que não recorri para realizá-lo, a nenhuma forma de ajuda externa, exceto quando autorizado pelo professor tutor.

Rio de Janeiro

Novembro/2021

As opiniões expressas nesse trabalho são de responsabilidade única e exclusiva do autor.

AGRADECIMENTOS

Primeiramente, gostaria de agradecer à minha mãe, Jacqueline El-Jaick, pelo apoio incondicional em todas as etapas da vida que me levaram até aqui. Por ter me ensinado a sempre dar, pelo menos, o meu melhor e por ser o meu maior exemplo diário de força e caráter.

A todos os professores que tive ao longo desta jornada e que contribuíram constantemente para a certeza de que as Ciências Econômicas são, de fato, o meu maior fascínio. Ao Rogério Werneck, ao Stefan, ao Juarez, à Maria Gabriela e ao Miguel Foguel.

Em especial, agradeço ao Márcio Garcia, que me orientou durante a construção do presente trabalho. Foi um privilégio poder discutir e aprender com ele neste fechamento de curso.

Agradeço muito ao Gustavo Pinto, co-orientador, que foi fundamental para o sucesso deste trabalho, trazendo questionamentos e sugestões constantemente. Obrigada pela paciência.

Aos meus amigos, obrigada pela companhia nos sufocos e nas alegrias desta graduação. É um privilégio me formar ao lado de pessoas tão incríveis quanto vocês.

Agradeço à Julia Bretz e ao José Pugas por me darem a imensa oportunidade de aprender, diariamente, sobre o agronegócio brasileiro. É um prazer inenarrável trabalhar com vocês.

Por fim, agradeço ao Laio, por acreditar em mim e me fazer tão feliz. Sem ele, nada disso teria graça.

SUMÁRIO

PRÓLOGO	8
1. INTRODUÇÃO	11
2. DADOS	14
2.1 Dados Agrícolas	14
2.2 Dados Climáticos	16
2.3 Projeções do IPCC	17
3. METODOLOGIA	21
3.1 Construção do Painel	21
3.2 Modelo Econométrico	24
4. RESULTADOS	27
4.1 Regressões	27
4.2 Projeções de Impacto de Produtividade	32
5. CONCLUSÃO	40
6. REFERÊNCIAS BIBLIOGRÁFICAS	42
7. APÊNDICES	47

LISTA DE FIGURAS

Figura 1: <i>Reference Regions</i> (IPCC)	19
Figura 2: <i>Reference Regions</i> x Brasil	20
Figura 3: Processo de Interpolação Espacial de Desvios Climáticos	23
Figura 4: Períodos de Safra – Soja	30
Figura 5: Períodos de Safra – Milho (Primeira Safra).....	30
Figura 6: Períodos de Safra – Milho (Segunda Safra).....	31
Figura 7: Projeções de Impacto (%) para Soja, SES	34
Figura 8: Projeções de Impacto (%) para Soja, SAM.....	35
Figura 9: Projeções de Impacto (%) para Milho, SES.....	36
Figura 10: Projeção de Impacto (%) para Milho, SES	36
Figura 11: Safras de Milho no Brasil	37
Figura 12: Projeção de Impacto (%) para Cana, SES.....	38
Figura 13: Projeção de Impacto (%) para Cana, NES	38

LISTA DE TABELAS

Tabela 1: Representatividade das 4 Principais Culturas Agrícolas Nacionais	15
Tabela 2: Soja – Produção (Milhões de Toneladas) – Ranking 2020	16
Tabela 3: Açúcar – Produção (Milhões de Toneladas) – Ranking 2020	16
Tabela 4: Milho – Produção (Milhões de Toneladas) – Ranking 2020.....	16
Tabela 5: <i>Shared Socioeconomic Pathways</i> (SSPs)	18
Tabela 6: Resultados Econométricos das Regressões	29
Tabela 7 : Comparação de Produção de Soja entre as <i>Reference Regions</i>	33
Tabela 8: Comparação de Produção de Milho entre as <i>Reference Regions</i>	33
Tabela 9: Comparação de Produção de Cana entre as <i>Reference Regions</i>	33
Tabela 10: CAGR de Produtividade Histórica	39

PRÓLOGO

Diante da questão da crise ecológica global e da evolução do pensamento econômico no que tange às relações entre a sociedade e a natureza, a desconstrução crescente do preceito de que há algum *tradeoff* entre crescimento econômico e meio ambiente é uma das conquistas recentes mais importantes (ROMEIRO, 2012). Esse advento tem sido verificado por alguns movimentos macroeconômicos que sugerem o ímpeto global rumo a uma economia de baixo carbono. Dentre eles: (i) alterações na dinamicidade de oferta e demanda de determinados setores¹, (ii) a articulação das relações internacionais – e aqui, incluem-se as mudanças regulatórias e suas implicações para com o mercado internacional –² e (iii) suas respectivas consequências diretas e indiretas sobre o mercado de capitais³.

¹ E.g.: Crise energética na China (Bloomberg, 2021); movimentos inflacionários em commodities (The Economist, 2021); aumento abrupto na demanda por minerais especiais (BNEF, 2021) – cabe ressaltar a relevância destes para a produção de painéis fotovoltaicos –, como o polissilício, que viu seu preço mais do que dobrar durante o ano de 2021; a revisão por parte da Agência Internacional de Energia acerca da oferta esperada de combustíveis fósseis e energias renováveis para atingir o *Net Zero* em 2050 (IEA, 2021) – a agência parou de considerar o crescimento de renováveis como linear e passou a considerá-lo exponencial.

² E.g.: A definição do Acordo de Paris em 2015; a articulação do *European Green Deal* em 2019 e a consequente definição da proposta de uma *carbon border*, através do CBAM, por parte da União Europeia em 2021; a disputa pela liderança tecnológica em renováveis como um componente importante da competição geopolítica entre China e EUA (Carbon Tracker, 2021); o *Due Diligence Act* (Comissão Europeia, 2021), estabelecendo a obrigatoriedade de asseguarção, por parte dos importadores europeus, da ausência de desmatamento atrelado produtos importados de carne bovina, soja, café, cacau, madeira e óleo de palma. Ainda, cabe mencionar a existência de diversos acordos firmados na COP26 de 2021, tais como: o *International Public Support for the Clean Energy Transition*, visando encerrar o financiamento internacional a combustíveis fósseis (excluindo financiamentos nacionais, internos), por parte dos países signatários; e o *Global Methane Pledge*, que visa cortar em 30% emissões de metano até 2030.

³ E.g.: O aumento explosivo do número de títulos sustentáveis emitidos anualmente (BNEF, 2021); o aumento do número de fundos de investimento com mandato ESG (BNEF, 2021); o aumento da regulação sobre investimentos sustentáveis (SFDR, 2020, IOSCO, 2021 e CVM, 2021); a aplicação pelo Banco Central da Inglaterra (ECB) de testes de estresse de carbono; o reconhecimento por parte da agência de Ratings, Moody's, da possibilidade da deterioração de ratings de crédito devido a exposições a ativos fósseis (Moody's, 2021).

Fundamentalmente, essas modificações de incentivos, interesses e posicionamento dos agentes econômicos – públicos e privados –, em busca da descarbonização, estão sustentadas na urgência da adaptação do comportamento humano para permitir sua própria longevidade, cada vez mais denunciada cientificamente (IPCC, 2021). Isto é, a relação que, no início das correntes eco-desenvolvimentistas, perpassava pelo princípio de “precaução” (ROMEIRO, 2012), hoje, nada mais é, do que um princípio de sobrevivência – da espécie, das empresas e do sistema econômico como um todo. A definição desse entendimento decorre do fato de que adquirimos conhecimento científico suficiente para julgar com assertividade que o resultado de manter o estado econômico como *business as usual* (BAU) trará implicações sociais, econômicas e de bem-estar negativas e relevantes (IPCC, 2021 e IEA, 2021).

Reconhecendo que a ação antropológica de fato é responsável pelo aquecimento global⁴ e que é necessária a mudança do comportamento humano para contê-lo, torna-se comum a atribuição de responsabilidade por setor econômico. Isto é, a análise de contribuição de emissões de gases de efeito (GEE) por atividade econômica, visando entender quais seriam os setores mais intensivos em carbono e que precisam se adaptar. Nesse sentido, o *6th Assessment Report* (AR6) do IPCC define que “*The main human causes of climate change are the heat-absorbing greenhouse gases released by fossil fuel combustion, deforestation, and agriculture, which warm the planet, and aerosols such as sulphate from burning coal*”, refletindo a conclusão consensual no campo das ciências climáticas de que as principais atividades que contribuíram nas últimas décadas para o aumento do estoque de GEE na atmosfera são as de energia e queima de combustíveis fósseis e de agricultura⁵ – dados trazidos pela UNEP (2021), OCDE (2019) e US-EPA (2019) contribuem para essa definição.

⁴ Conforme o *6° Assessment Report* (AR6) do Painel Intergovernamental sobre Mudanças Climáticas da ONU (IPCC), “*These changes [climatic changes during the 20th century] are attributed to human influence in almost all regions (medium to high confidence) and will continue through the 21st century (high confidence)*”.

⁵ Cabe destacar que, as emissões atreladas à agricultura e agropecuária são não somente aquelas relacionadas a atividade em si, como também aquelas derivadas da mudança do uso do solo (LUC) e da mudança indireta do uso do solo (ILUC) – LUC e ILUC correspondem à alteração direta e indireta da paisagem natural para ocasionada pelo uso funcional da terra para fins econômicos (IPCC, 2021: AR6, *Glossary*) – que são especialmente significativas para essa atividade econômica (IPCC, 2021).

O Brasil, em especial, possui uma distribuição de emissões por setor distinta da média global, em função, principalmente, de sua matriz energética significativamente menos dependente de combustíveis fósseis⁶ e pela representatividade significativa do setor da agropecuária na economia nacional. Para dimensionar, de acordo com dados da OCDE⁷, em 2014 45% das emissões de GEE do Brasil foram provenientes do setor de energia e 40% da agricultura. Enquanto isso, da totalidade das emissões dos países que compõem a OCDE, 80,5% vieram do setor de energia e apenas 9,24% do setor agrícola. Com isso, a agricultura possui uma relevância relativa significativa para a contribuição brasileira para o aquecimento global.

O presente trabalho procura testar a hipótese de que as mudanças climáticas podem ter impactos sobre a própria atividade econômica da agricultura. Se por um lado a agropecuária nacional contribui significativamente para o balanço de emissões de gases de efeito estufa, por outro esta pode ser afetada pelos desdobramentos dessas emissões?

⁶ Em 2019, do total de energia consumida no país, 17,6% eram provenientes de energia elétrica e 6,2% de etanol, sendo que 84,5% da capacidade instalada nacional de geração de energia elétrica é de fontes renováveis (EPE, 2021: Plano Decenal de Expansão de Energia 2024. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Plano-Decenal-de-Expansao-de-Energia-2024> Acesso em: 26/11/2012).

⁷ OECD Library, 2021: *Greenhouse gas emissions by source*. Disponível em: https://www.oecd-ilibrary.org/environment/data/oecd-environment-statistics/greenhouse-gas-emissions_data-00594-en. Acesso em: 26/11/2021.

1. INTRODUÇÃO

Conforme amplamente discutido pela literatura da agrometeorologia, o sucesso produtivo das atividades agrícolas possui certa dependência de condições climáticas – Petr (1990), Fageria (1992), Hoogenboom (2000), Pereira (2007), Monteiro (2009). Em algumas culturas, a variabilidade climática pode explicar até 80% da variabilidade produtiva agrícola (HOOGENBOOM, 2000). Essa relação de causalidade reside no fato de que condições como temperatura do ar, pluviosidade, radiação solar e temperatura do solo afetam etapas cruciais de desenvolvimento das plantas, como seu crescimento e reprodução (HOOGENBOOM, 2000).

Ainda, há um canal indireto de influência climática sobre as safras: o controle de pragas e doenças (HOOGENBOOM, 2000). Isso porque as fases do ciclo vital dos fitopatógenos são dependentes de condições climáticas, como, por exemplo, temperatura e incidência de pluviosidade – condicionantes para a germinação e penetração das pragas agrícolas (PEREIRA, 2007). Inclusive, em vista da incidência de ferrugem-asiática⁸, por exemplo, há no Brasil o estabelecimento de janelas para a semeadura de soja – muitas vezes de maneira normativa⁹ –, em vista dos potenciais prejuízos de se estender esse período para além do intervalo considerado seguro do ponto de vista de condições climáticas.

Dado essa relação entre condições climáticas e produção agrícola, torna-se cada vez mais uma preocupação entre produtores e formuladores de políticas públicas a crescente ocorrência de adversidades climáticas, tais como secas, geadas, *La Niña* e tantos outros (FAO, 2021 e *University of Illionis*, 2020). Nesse sentido, a literatura de ciências climáticas tem se debruçado sobre a possibilidade de um impacto ainda mais severo sobre as safras decorrente de modificações climáticas estruturais, em observância do aquecimento global¹⁰ (AYDNALP, 2008, USDA, 2015, VANDYCK, 2018, CHANDIO, 2020 e IPCC, 2021).

⁸ A ferrugem-asiática é considerada a mais severa doença que acomete a cultura da soja, podendo causar perdas de até 90% de produtividade se não controlada (EMBRAPA, Ferrugem da soja: manejo e prevenção. Disponível em: <https://www.embrapa.br/en/soja/ferrugem>. Acesso em: 26/11/2021).

⁹ E.g.: Instrução Normativa Conjunta SEDEC/INDEA-MT N° 002/2.015.

¹⁰ Conforme o 6° *Assessment Report* (AR6) do Painel Intergovernamental sobre Mudanças Climáticas da ONU (IPCC): “*In particular, extreme heat would exceed critical thresholds for health, agriculture and other sectors more frequently by the mid-21st century with 2°C of global warming (high confidence)*”.

Diante do exposto acima, a presente monografia esforçou-se por testar a hipótese de que as mudanças climáticas podem ter impactos estatisticamente significativos sobre a produtividade agrícola do Brasil. Utiliza-se, portanto, da premissa da agrometeorologia de uma relação exógena entre variáveis climáticas e produtividade agrícola (INMET, 2021)¹¹. Serão discutidas questões como a dimensão do impacto de novos regimes de chuva e temperatura, a distinção do impacto dentre as diferentes culturas estudadas e regiões brasileiras e a sensibilidade do impacto aos diferentes cenários de mudanças climáticas.

Para tanto, baseado na metodologia empregada por SOUZA (2018)¹², foram construídos painéis a nível municipal, para as três principais culturas em termos de produto agrícola nacional – soja, milho e cana-de-açúcar, conforme discutiremos nos próximos capítulos. As informações contidas em nossos painéis são de produtividade (kg/Ha), de temperatura (desvio percentual de temperatura em relação à média histórica) e de pluviosidade (desvio percentual de pluviosidade em relação à média histórica). A partir desses painéis, realizamos regressões econométricas que estimam o impacto em produtividade agrícola causado pelo desvio percentual de chuva e de temperatura. Em seguida, utilizam-se projeções de variáveis climáticas formuladas pelo 6º *Assessment Report* (AR6) do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) – uma versão mais recente do AR5 utilizado por SOUZA (2018) –, a fim de projetar qual seria o potencial impacto de diferentes cenários climáticos sobre a produtividade agrícola nacional nos próximos 80 anos.

Os resultados obtidos pelo modelo econométrico indicam uma relação negativa entre variabilidade climática e produtividade agrícola. Tal impacto varia entre -55,7% e -10,4% de variação anual de produtividade ocasionada por desvios percentuais de temperatura e entre +0,5% e +1,2% de variação anual de produtividade ocasionada por desvios percentuais de pluviosidade – se considerados os efeitos mensais de maneira

¹¹ INMET, 2009: Agrometeorologia dos Cultivos: O fator meteorológico na produção agrícola. Disponível em: https://www.embrapa.br/documents/1355291/37056285/Bases+climatol%C3%B3gicas_G.R.CUNHA_Livro_Agrometeorologia+dos+cultivos.pdf/13d616f5-cbd1-7261-b157-351eaa31188d?version=1.0

Acesso em: 26/11/2021.

¹² SOUZA, Bruno Santos de. **Mudanças climáticas no Brasil: efeitos sistêmicos sobre a economia brasileira provenientes de alterações na produtividade agrícola**. 2018. Dissertação (Mestrado em Teoria Econômica) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2018. doi:10.11606/D.12.2018.tde-15102018-113337. Acesso em: 19/09/2021.

agregada. Diante das projeções utilizadas, baseadas nos *Shared Socioeconomic Pathways* (SSP), encontramos impactos de produtividade para os próximos 80 anos em sua maioria negativos. Os resultados variaram entre as diferentes culturas, apresentando perdas na casa de 25%, 50% e até mais do que 200%. Para algumas regiões, encontramos trajetórias de impacto positivo, em uma faixa de 25% a 50%.

Esse trabalho foi dividido em 3 capítulos, além desta introdução. No capítulo 2, discorre-se sobre os dados que alimentaram as análises em questão. Em seguida, a metodologia utilizada na análise é discutida, apresentando o modelo econométrico de efeitos fixos adotado e as projeções do IPCC escolhidas para projetar os impactos, a partir das estimativas construídas. No capítulo 3, os resultados obtidos nesta monografia são apresentados, explicitando diferenças entre as culturas agrícolas consideradas e entre as regiões geográficas. Por fim, as conclusões do trabalho são feitas e suas limitações são discutidas.

2. DADOS

A presente monografia se utilizou, principalmente, de três conjuntos de bases de dados – PAM, INMET e IPCC, conforme detalhado nos subcapítulos a seguir – para construção de:

- (i) um painel de dados históricos agrícolas e climáticos a nível municipal e;
- (ii) uma base de dados de projeções de variáveis climáticas para os próximos 80 anos para diferentes regiões geográficas nacionais.

Para a obtenção dos dados históricos agrícolas, foram usados dados fornecidos pelo IBGE a nível municipal e anual, especificamente, dados de Produção Agrícola Municipal (PAM), conforme discutido em detalhe a seguir.

Já para a obtenção de dados históricos climáticos, foram usados dados fornecidos pelo Instituto Nacional de Meteorologia (INMET), a nível horário, referentes a 587 estações meteorológicas espalhadas pelo território nacional, conforme discutido em detalhe no capítulo 2.2.

Finalmente, os dados escolhidos para projeções de variáveis climáticas foram fornecidos pelo 6º *Assessment Report* do IPCC (AR6), em nível mensal, com agregação em *Reference Regions* mundiais, definidas pela instituição, dentre as quais 4 interseccionam com o território nacional, conforme discutido em detalhe no final deste capítulo.

2.1 Dados Agrícolas

O IBGE¹³ fornece dados anuais agregados a nível municipal para as diferentes culturas agrícolas nacionais. As variáveis de produção agrícola fornecidas são: Área Colhida (Ha), Área Plantada (Ha), Quantidade Produzida (toneladas), Rendimento Médio da Produção (kg/Ha) e Valor da Produção (mil reais).

Os dados do Produção Agrícola Municipal (PAM) utilizados dizem respeito ao período de 2001 a 2020, 20 anos, sendo particularmente interessante por fornecer as informações mais recentes de produção agrícola, com menos de um ano de defasagem em

¹³ IBGE, Sidra – Tabela 5457 – Produção Agrícola Municipal: Área plantada ou destinada à colheita, área colhida, quantidade produzida, rendimento médio e valor da produção das lavouras temporárias e permanentes. Disponível em: <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 01/07/2021.

relação à data desta pesquisa. Ainda, foram incluídas observações para todos os 5.563 municípios.

As informações da PAM são divididas entre dois grupos: culturas temporárias e permanentes. Cabe explicar que, as culturas temporárias são aquelas de curta ou média duração, sujeitas ao replantio pós-colheita – o plantio rende apenas uma colheita –, como por exemplo a soja, o milho, o feijão e a cana-de-açúcar. Diferentemente, as culturas permanentes são colhidas mais de uma vez após o primeiro plantio, como por exemplo a laranja e o café (IBGE, 2020).

Desde 1992, soja, cana-de-açúcar e milho são as três principais culturas do PIB agrícola nacional, tendo representado nesse período de 29 anos, em média, 24,2%, 15,8% e 11,9% do PIB agrícola¹⁴, respectivamente. Em vista disso, essas foram as culturas escolhidas para análise. Conforme a Tabela 1 indica, nos últimos 5 anos, essas três culturas foram responsáveis conjuntamente por 63% do PIB, em média.

Tabela 1: Representatividade Percentual das 4 Principais Culturas Agrícolas Nacionais

	2016	2017	2018	2019	2020
Soja	32,8	35,4	37,2	34,7	35,9
Cana-de-açúcar	16,1	17,0	15,2	15,1	15,7
Milho	11,8	10,4	11,0	13,2	12,9
Outros	39,3	37,2	36,6	37,0	35,4

Fonte: elaboração própria a partir de dados do IBGE, PAM - Tabela 5457.

Ainda, apesar de não compor o critério de seleção utilizado, cabe comentar que essas três culturas estão entre os produtos de maior relevância na balança comercial agrícola (EMBRAPA, 2020), auferindo aprovação adicional a essa escolha. Inclusive, atualmente, o Brasil é o maior produtor mundial de soja e açúcar e é o terceiro maior produtor de milho, conforme as Tabelas 2, 3 e 4.

¹⁴ IBGE, Sidra – Tabela 5457 – Produção Agrícola Municipal: Área plantada ou destinada à colheita, área colhida, quantidade produzida, rendimento médio e valor da produção das lavouras temporárias e permanentes.

Tabela 2: Soja - Produção (Milhões de Toneladas) - Ranking 2020

	Mundo	1º Brasil	2º EUA	3º Argentina	4º China	5º Índia	6º Paraguai	7º Canadá	8º Ucrânia	9º Rússia	10º Bolívia
2020	371	126	121	53	15	12	11	8	5	5	3
%	100%	34%	33%	14%	4%	3%	3%	2%	1%	1%	1%
2000-2020	5.466	1.537	1.934	913	308	211	139	96	43	37	45
%	100%	28%	35%	17%	6%	4%	3%	2%	1%	1%	1%

Fonte: FAOSTAT e EMBRAPA, elaboração própria.

Tabela 3: Açúcar - Produção (Milhões de Toneladas) - Ranking 2020

	Mundo	1º Brasil	2º Índia	3º Tailândia	4º China	5º Paquistão	6º EUA	7º México	8º Rússia	9º França	10º Colômbia
2020	2.261	766	384	127	115	78	62	60	54	43	31
%	100%	34%	17%	6%	5%	3%	3%	3%	2%	2%	1%
2000-2020	40.198	12.853	6.796	1.747	2.381	1.236	1.243	1.102	700	732	733
%	100%	32%	17%	4%	6%	3%	3%	3%	2%	2%	2%

Fonte: FAOSTAT e EMBRAPA, elaboração própria.

Tabela 4: Milho - Produção (Milhões de Toneladas) - Ranking 2020

	Mundo	1º EUA	2º China	3º Brasil	4º Argentina	5º Ucrânia	6º Indonésia	7º México	8º Índia	9º Canadá	10º França
2020	1.226	389	287	100	56	37	31	29	29	14	13
%	100%	32%	23%	8%	5%	3%	3%	2%	2%	1%	1%
2000-2020	18.541	6.639	3.962	1.313	581	370	379	482	424	238	307
%	100%	36%	21%	7%	3%	2%	2%	3%	2%	1%	2%

Fonte: FAOSTAT e EMBRAPA, elaboração própria.

2.2 Dados Climáticos

Os dados climáticos fornecidos pelo Instituto Nacional de Meteorologia (INMET)¹⁵, informam o histórico para uma série de variáveis climáticas de 572 estações meteorológicas, das quais 379 estão correntemente operantes. As informações são fornecidas em nível horário, para cada estação.

O INMET possui dados históricos para 17 variáveis climáticas, das quais selecionamos 2 para nossa pesquisa, tal qual a metodologia utilizada por SOUZA (2018): Precipitação Total e Temperatura do Ar. Essa escolha é reforçada pela literatura de

¹⁵ INMET. Dados Históricos Anuais. Disponível em: <https://portal.inmet.gov.br/dadoshistoricos>. Acesso em: 01/07/2021.

agrometeorologia, dado que estas são duas das principais variáveis climáticas observadas em estudos de ciência climática (HOOGENBOOM, 2000)¹⁶.

Além disso, são as duas variáveis para as quais o IPCC disponibiliza publicamente suas projeções para os próximos 80 anos. Assim, aferimos comparabilidade entre as variáveis que alimentam nosso modelo do ponto de vista histórico (fundamental para a regressão feita) e as variáveis que alimentam nosso modelo do ponto de vista de projeções.

Cabe ressaltar que, apesar de as informações serem a nível horário, nesta monografia fizemos um tratamento para agregá-las a nível mensal, garantindo um nível de granularidade compatível com as demais informações, mas preservando o componente sazonal intrínseco às variáveis climáticas. Isto é, informações em nível anual para temperatura e pluviosidade teriam um nível de agregação que omitiria a relevância de determinados meses para determinadas safras.

2.3 Projeções do IPCC

Optamos por usar estimativas fornecidas pela entidade mais respeitada na comunidade de ciências climáticas, o Painel Intergovernamental sobre Mudanças Climáticas, instituição da ONU voltada para esse campo de pesquisa. Fundado em 1988, o IPCC publica relatórios desde 1990 discorrendo sobre o desafio das mudanças climáticas, que são constantemente atualizados. Entre 2014 e 2018, o IPCC fez publicações acerca de seu quinto relatório, o *Fifth Assessment Report* (AR5), que foram fundamentais para a formulação de uma série de políticas climáticas discutidas no Acordo de Paris¹⁷. Recentemente, em agosto/2021, o IPCC publicou uma primeira versão do seu *Sixth Assessment Report* (AR6), a ser finalizado em 2022. Tal publicação conferiu a este trabalho a possibilidade de estimar impactos climáticos com embasamento científico com um grau de defasagem baixo.

Apesar de o *Assessment Report 6* (AR6) ainda estar em finalização, o seu conteúdo público já fornece um conjunto principal de 5 cenários de projeções climáticas, baseados

¹⁶ HOOGENBOOM, G. *Contribution of agrometeorology to the simulation of crop production and its application*. Agricultural and Forest Meteorology, 103, 137-157, 2000.

¹⁷ IPCC, 2021: About: The Reports. Disponível em: <https://www.ipcc.ch/about/history/>. Acesso em: 26/11/2021.

nos *Shared Socioeconomic Pathways* (SSPs), sendo estes SSP1-1.9, SSP1-2.6, SSP2-4.5, SSP3-7.0 e SSP5-8.5. Os SSPs descrevem uma gama de trajetórias plausíveis para a sociedade ao longo do século 21, a partir de premissas qualitativas e quantitativas para *inputs* como consumo de energia, controle de poluição, uso da terra, emissões de gases de efeito estufa, crescimento populacional, PIB e urbanização (IPCC, 2021)¹⁸. Esse conjunto de cenários é mais extenso do que apresentado no relatório anterior (AR5), incluindo 2 novos cenários extremos, tanto para alto nível de emissões – mais aquecimento –, quanto para baixo nível de emissões – menos aquecimento. Os cinco SSPs representam, respectivamente, uma trajetória “sustentável”, uma no “meio do caminho”, uma de “rivalidade regional”, uma de “desigualdade” e uma “intensa em combustíveis fósseis” (IPCC, 2021).

A Tabela 2 ilustra qual seria o aquecimento médio, em graus Celsius (°C), esperado a partir de cada cenário, resultante de diferentes trajetórias socioeconômicas para os próximos 80 anos. É importante ressaltar que essas informações servem aqui ao propósito de ilustrar a diferença de aquecimento projetado por cada um dos cenários apenas, visto que, tratando-se de aquecimento médio, não contempla as distinções regionais de impactos das mudanças climáticas – relevante para a pesquisa em questão.

Tabela 5: *Shared Socioeconomic Pathways* (SSPs) - Incrementos de Temperatura Média Global

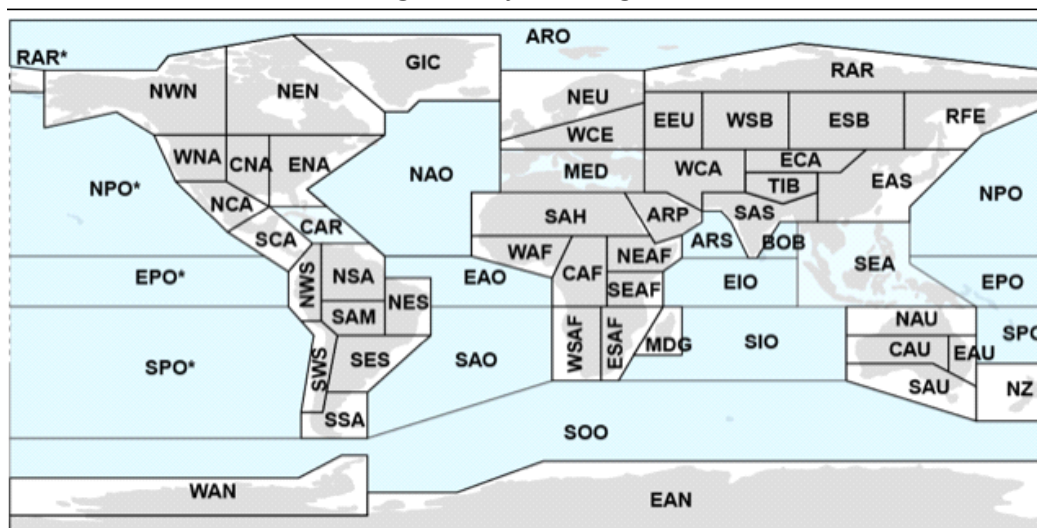
Cenário	Curto Prazo 2021-2040		Médio Prazo 2041-2060		Longo Prazo 2081-2100	
	Estimativa Otimista (°C)	Intervalo Provável (°C)	Estimativa Otimista (°C)	Intervalo Provável (°C)	Estimativa Otimista (°C)	Intervalo Provável (°C)
SSP1-1.9	1.5	1,2 - 1,7	1.6	1,2 - 2,0	1.4	1,0 - 1,8
SSP1-2.6	1.5	1,2 - 1,8	1.7	1,3 - 2,2	1.8	1,3 - 2,4
SSP2-4.5	1.5	1,2 - 1,8	2.0	1,6 - 2,5	2.7	2,1 - 3,5
SSP3-7.0	1.5	1,2 - 1,8	2.1	1,7 - 2,6	3.6	2,8 - 4,6
SSP5-8.5	1.6	1,2 - 1,9	2.4	1,9 - 3,0	4.4	3,3 - 5,7

Fonte: IPCC, elaboração própria.

¹⁸ Chen, D., M. Rojas, B.H. Samset, K. Cobb, A. Diongue Niang, P. Edwards, S. Emori, S.H. Faria, E. Hawkins, P. Hope, P. Huybrechts, M. Meinshausen, S.K. Mustafa, G.-K. Plattner, and A.-M. Tréguier, 2021: **Framing, Context, and Methods**. In **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press. In Press.

Os dados de projeções a nível mensal para cada um desses cenários foram obtidos a partir de um repositório *GitHub*¹⁹ fornecido pelo próprio IPCC²⁰, contendo informações segregadas entre diferentes regiões chamadas de *Reference Regions*, conforme a Figura 1. Outra contribuição importante que o AR6 teve para nossa pesquisa, em relação a estudos baseados no AR5, é que neste novo relatório, o nível de agregação de regiões diminuiu, garantindo maior granularidade de projeções regionais.

Figura 1: *Reference Regions*



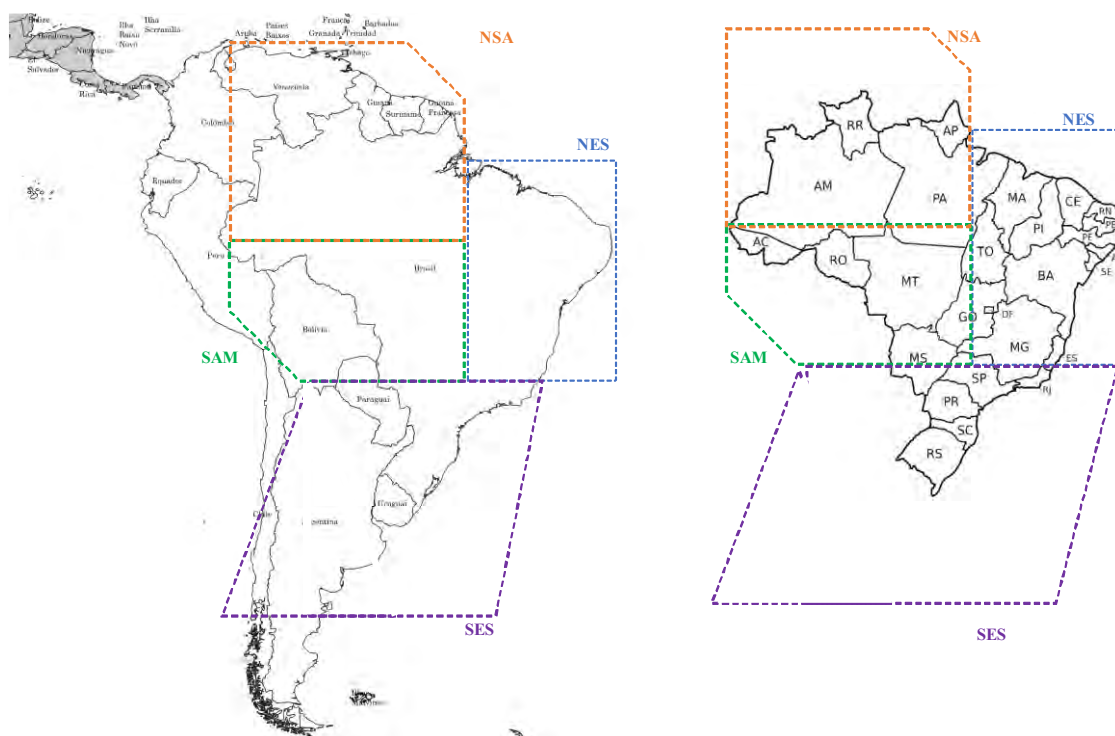
Fonte: IPCC, 2021.

Para o presente trabalho, utilizamos projeções climáticas referentes às 4 regiões que interseccionam com o território nacional, sendo estas *N. South-America* (NSA), *N.E. South-America* (NES), *South-American-Monsoon* (SAM) e *S.E. South America* (SES), conforme disposto no Figura 2.

¹⁹ IPCC. Official GitHub repository for IPCC-WG1. Disponível em: <https://github.com/IPCC-WG1>. Acesso em: 01/11/2021.

²⁰ O repositório fornece informação para os 4 cenários mais relevantes do ponto de vista de estudos de impacto, o SSP1-2.6, SSP2-4.5, SSP3-7.0 e SSP5-8.5. O SSP1-1.9 não é incluído, porém isso não representa uma perda relevante de conteúdo, dado que é o cenário mais otimista, de modo que seus impactos projetados são entendidos como residuais comparado aos demais.

Figura 2: Reference Regions x Brasil



Fonte: Elaboração própria, a partir de mapas do IPCC.

3. METODOLOGIA

Para traçar relações de causalidade entre variáveis climáticas e variáveis de produtividade agrícola, o presente trabalho construiu painéis municipais com informações de temperatura mensal e pluviosidade mensal para os 12 meses do ano, informações de produção agrícola anual e coordenadas geográficas para os municípios brasileiros. A partir dos painéis para as 3 diferentes culturas agrícolas, foi possível estimar regressões em painel, considerando como variável dependente a produtividade agrícola (kg/Ha) de cada município em cada ano. Neste sentido, procuramos estimar as relações entre produtividade e condições climáticas, em especial sob a ótica de desvios percentuais de temperatura e pluviosidade, em relação às suas médias históricas, conforme sugerido pela metodologia abordada por SOUZA (2018).

A partir das regressões construídas, a serem detalhadas a seguir, pode ser encontrada a influência das variações de temperatura e de chuva sobre a produtividade agrícola (kg/Ha) para cada cultura. Em seguida, utilizamos as projeções regionais fornecidas pelo IPCC para temperatura e pluviosidade e encontramos os desvios percentuais projetados em relação à média que foi estimada para os 20 anos de análise (2001-2020). A partir dos desvios percentuais estimados²¹ e dos estimadores de impacto de produtividade resultantes das regressões, conseguimos projetar impactos de produtividade agrícola para soja, milho e cana-de-açúcar entre 2021 e 2100, dados os diferentes cenários do IPCC.

3.1 Construção do Painel

A construção dos painéis municipais perpassou por duas principais etapas: agregação de dados e interpolação de dados.

Uma vez que os dados climáticos fornecidos pelo INMET são observações em base horária, foi feita uma agregação dos mesmos em base mensal, gerando observações para os 20 anos selecionados (2001-2020). Além disso, foi calculada qual seria a média da série histórica analisada para cada uma das duas variáveis climáticas, a nível de estação meteorológica. Dessa maneira, encontramos os desvios percentuais em relação à média

²¹ A informação de temperatura e pluviosidade futura é fornecida pelo IPCC, porém o desvio em relação à média foi estimado, usando como base a média de temperatura e pluviosidade dos últimos 20 anos calculada no decorrer deste trabalho.

histórica para as variáveis de temperatura e pluviosidade para cada estação meteorológica. Como exemplo, encontramos a média de temperatura para o mês de janeiro entre os anos de 2001 e 2020 para a estação “Abrolhos”, a partir dessa média, obtivemos a informação de desvio de temperatura percentual em relação à média de temperatura de janeiro para todos os meses de janeiro entre 2001 e 2020 para a estação “Abrolhos”.

A partir dos dados construídos para as estações do INMET, fizemos uma interpolação espacial, conforme SOUZA (2018), para estimar informações a nível municipal de desvio de temperatura e pluviosidade histórico (2001-2020)²². Isto é, a partir do desvio histórico mensal para as 587 estações, foi estimado, a partir da referida interpolação, o desvio para cada um dos 5.563 municípios englobados no conjunto de dados de Produção Agrícola. O processo feito está descrito abaixo:

1. A partir de informações públicas do IBGE com detalhamento de coordenadas geográficas para os municípios brasileiros, conseguimos estabelecer uma base comum de referência espacial (latitude e longitude) entre estes e as estações meteorológicas – cujas coordenadas são fornecidas pelo INMET.
2. Criamos um *grid* de coordenadas geográficas a nível de granularidade de 0,1 grau de longitude e latitude, com latitude mínima de $-33,69^\circ$ e máxima de $4,59^\circ$ e com longitude mínima de $-72,92^\circ$ e máxima de $-32,44^\circ$ ²³.
3. Interpolamos²⁴ informações de temperatura e de pluviosidade para encontrar informações interpoladas para todos os pares de coordenadas geográficas contidos no *grid* construído.

A Figura 3 abaixo indica o *grid* construído e a distribuição geográfica das estações do INMET contendo observações históricas de desvios climáticos que foram usadas para encontrar estimativas para os municípios via interpolação espacial. No mapa, as estações em verde são estações operantes e as estações em azul são estações que, correntemente, estão em estado de pane. Essa informação é relevante e uma limitação do estudo aqui

²² A interpolação espacial foi feita através da ferramenta RStudio, em linguagem R. O nível de resolução adotado para a interpolação foi de 0,1 grau de longitude e latitude. Como base de referência, 1° de latitude corresponde a uma distância de 111,12 km.

²³ Esses limites foram selecionados com base nos mínimos e máximos de coordenadas geográficas aferidos nos municípios nacionais.

²⁴ O pacote utilizado para a interpolação foi o “interp”: Albrecht Gebhardt, Roger Bivand and David Sinclair (2020). *interp: Interpolation Methods*. R package version 1.0-33. <https://CRAN.R-project.org/package=interp>.

feito, visto que temos a construção de uma interpolação desbalanceada, em que temos mais informações para determinados anos e menos informações para outros. Ao longo dos anos, o INMET acrescentou e aposentou diferentes estações, de modo que algumas estações utilizadas para a interpolação não apresentam informação para todos os 20 anos considerados. Como resultado, teremos informações interpoladas para todos os municípios brasileiros, para todos os anos, porém com grau de precisão distinta – dado que alguns anos possuem informação proveniente de um número maior de estações alimentando o processo de interpolação²⁵.

Figura 3: Processo de Inteporlação Espacial de Desvios Climáticos

GRID USADO



Fonte: elaboração própria

²⁵ Como exemplo, para 2020, temos informação de 589 estações meteorológicas sendo utilizadas como *input* para a interpolação. Já para 2016, temos 529 estações provendo *input* para a interpolação, de modo que os valores interpolados para 2016 contam com um número de observações menos granulares, de modo a perder precisão, comparado a 2020.

3.2 Modelo Econométrico

O modelo econométrico adotado neste trabalho toma como base a Equação (1), em que é estabelecida a relação entre produtividade agrícola e as variáveis climáticas de temperatura e pluviosidade. Esta é uma adaptação da equação proposta por SOUZA (2018)²⁶:

$$y_{it}^h = \alpha_i + \gamma_{st} + \theta_{c1}(C1_{it}) + \theta_{c2}(C2_{it}) + \epsilon_{it} \quad (1)$$

Nesta equação, temos que y_{it}^h é a produtividade agrícola da cultura h , no município i , no determinado período t . α_i corresponde ao efeito-fixo de município e γ_{st} é o efeito-fixo a nível de Estado-Ano.

Quanto aos parâmetros a serem regredidos: θ_{c1} é o primeiro parâmetro de interesse, que mede o impacto de desvios percentuais de temperatura sobre a produtividade agrícola de uma determinada cultura h e θ_{c2} é o segundo parâmetro de interesse que mede o impacto de desvios percentuais de pluviosidade sobre a produtividade agrícola dessa cultura. As variáveis climáticas usadas para encontrar os coeficientes de impacto foram $C1_{it}$, um vetor de desvios percentuais de temperatura média mensal, e $C2_{it}$, um vetor de desvios percentuais de pluviosidade acumulada.

$C1_{it}$ e $C2_{it}$ são vetores porque são compostos por 1 observação para cada um dos 12 meses de um ano. Isto é, estamos considerando em nossa regressão em painel o impacto que os desvios de temperatura em cada mês possuem sobre a produtividade de uma determinada cultura em um determinado município em um determinado ano. A partir disso, os parâmetros de interesse estimados mensuram o impacto que o desvio de 1 p.p. em relação à média de temperatura e de pluviosidade em cada mês possui sobre a produtividade anual de uma determinada cultura. Os parâmetros de interesse estimados também são vetoriais, visto que há um parâmetro associado a cada mês.

Inicialmente, foi adotado um controle para efeitos de ano, que buscasse controlar tendência linear de ganho de produtividade ao longo dos anos. Porém, com a adoção de efeitos-fixos estado-ano, as tendências já estavam sendo contempladas, sem que fosse necessário fazer suposições acerca da caracterização da tendência de ganho de

²⁶ Neste trabalho, consideramos regressão em painel com efeitos-fixos, de forma a termos a ausência de uma constante, diferentemente do que foi feito em SOUZA (2018).

produtividade ao longo dos anos – não necessariamente essa tendência é linear. Com isso, passamos a adotar o critério de efeitos-fixos estado-ano somente.

No caso desta regressão em painel, temos um painel curto e desbalanceado. A primeira caracterização define que o número de observações de corte transversal, isto é, número de municípios, é maior do que a escala temporal de anos (REINALDO, 2017). A segunda caracterização consiste no fato de que uma unidade de corte transversal não é necessariamente observada em todos os períodos – dado que nem todos os municípios tiveram produção das culturas agrícolas analisadas durante todos os 20 anos considerados²⁷.

O desbalanceamento do painel pode potencialmente prejudicar estimação, conforme MESQUITA (2020), a depender da natureza desse desequilíbrio: “a ausência de dados pode ser aleatória, o que pode prejudicar a eficiência dos coeficientes (erro padrão, p-valor, intervalos de confiança)”. Por outro lado, caso o desequilíbrio esteja relacionado com alguma variável de interesse do estudo, os estimadores podem apresentar vies. Como neste caso entendemos que o desbalanceamento não está relacionado com as variáveis de interesse – já que o desvio de temperatura mensal, em si^{28} , não exerce influência sobre o período o ano que um determinado município inicia sua produção agrícola para uma determinada cultura –, não enfrentamos a complicação de vies por desbalanceamento. Por outro lado, poderíamos encontrar coeficientes com erro padrão, p-valores e intervalos de confiança prejudicados. Porém, no que tange a eficiência dos estimadores, como estamos incluindo observações para 5.563 municípios, temos um

²⁷ Como exemplo, o município Rio Verde (GO) teve produção de cana-de-açúcar em todos os 20 anos considerados pela amostra (2001 a 2020). Por outro lado, o município Abadia de Goiás (GO), só teve produção de cana-de-açúcar em apenas 4 dos 20 anos considerados (2017 a 2020). Assim, o número de observações de produtividade entre as unidades de cortes transversal Rio Verde e Abadia de Goiás não é igual.

²⁸ Para que o desbalanceamento fosse viesado, seria necessário considerar que eventuais desvios de temperatura ou pluviosidade seriam *triggers* para a decisão de iniciar ou encerrar a produção de uma cultura em todo o município acometido em um determinado ano. O presente trabalho possui o entendimento de que a persistência de desvios pode ter essa consequência, porém sua ocorrência isolada tende a estar não relacionada com a decisão de plantar ou não determinada cultura em um determinado município.

número de observações suficientemente grande, a ponto de suprimir potenciais perdas de eficiência²⁹, sem comprometimento dos resultados³⁰.

A metodologia de regressão em painel nos permitiu flexibilidade para controlar algumas variáveis não observadas de difícil controle e que, caso não controladas, resultariam em viés de variável omitida nos estimadores dos parâmetros de interesse. Nesse sentido, regressões em painel permitem controlar pela heterogeneidade não observada nas unidades de corte transversal (MESQUITA, 2002). Isto é, ao incluir efeitos-fixos de município, controlamos para heterogeneidades invariantes no tempo (SOUZA, 2018). Com isso, controlamos tudo aquilo que é constante e inerente às unidades de corte transversal e impactam a variável dependente (produtividade). Adicionalmente, através do uso de efeitos-fixos para Estado-Ano, controlamos características comuns às unidades (estado, nesse caso), mas que variam ao longo do tempo, como por exemplo mudanças de legislação e inserção de novas tecnologias de mercado. Com isso, já é possível controlar boa parte da influência temporal sobre a produtividade agrícola³¹.

Com isso, adicionamos, no total, os efeitos em nossa regressão:

- Efeitos fixos de município: controlam para heterogeneidades entre municípios, fixas no tempo.
- Efeitos fixos de Estado_Ano: controlam para efeitos comuns entre os Estados que variam no tempo.

²⁹ Os intervalos de confiança, p-valores e erros padrões encontrados foram satisfatórios, conforme discutido no capítulo 3.

³⁰ Regressões com painéis desbalanceados são frequentemente utilizadas na literatura, em vista de falta de informação.

³¹ É especialmente importante assegurar-se de que estamos controlando para efeitos de tendência, dada ao notável e reconhecido ganho de produtividade da agricultura brasileiras nos últimos anos.

4. RESULTADOS

Na primeira parte deste capítulo, discorreremos sobre os resultados obtidos através das regressões que foram estimadas, conforme detalhado no capítulo anterior. Aqui, buscamos fornecer interpretação teórica dos estimadores e fornecer uma espécie de baliza para entender o nível de impacto sendo mensurado e comparar os resultados obtidos para as diferentes culturas.

Na segunda parte deste capítulo, explicamos as projeções de impacto das mudanças climáticas esperadas a partir das relações de causalidade que foram estimadas nas regressões em painel. Isto é, admitindo que o impacto que o desvio de pluviosidade e temperatura é dado – resultado da regressão – e admitindo diferentes cenários de desvio de pluviosidade e temperatura, fornecidos pelo IPCC, conseguimos estimar o impacto percentual em produtividade agrícola para as diferentes culturas em questão.

4.1 Regressões

Obtivemos estimativas acerca do impacto em produtividade causado pelo incremento de 1p.p. de desvio de temperatura (°C) e pluviosidade (mm) em relação à sua média histórica para soja, milho e cana-de-açúcar. As tabelas com os resultados encontrados estão nos apêndices A1, A2 e A3. As colunas (1) são os resultados isentos de controles de efeitos fixos, usando um modelo *pooled*. As colunas (2) são os resultados controlando para efeitos-fixos de município. As colunas (3) são os resultados com controles para efeitos-fixos de município e efeitos-fixos de ano. As colunas (4) são os resultados com controles para efeitos-fixos de município e de estado-ano³².

Para todas as culturas analisadas, foram encontrados regressores estatisticamente significativos, em níveis bastante altos de confiança, de 99%, inclusive, em muitos casos. Assim, confirmamos a hipótese deste trabalho de que há uma relação estatisticamente significativa de causalidade entre condições climáticas e produtividade agrícola.

³² Considerar ou não efeitos-fixos de ano não produz diferença nos coeficientes de interesse quando já considerados os efeitos-fixos de estado_ano. Pode-se entender que o efeito-fixo de estado_ano, quando utilizado individualmente, contempla o próprio efeito-fixo de ano. Com isso, em nossa regressão de foco (4), não incluímos efeitos fixos de ano, para não incluir variáveis para além do necessário, que possam reduzir a eficiência dos estimadores.

Na Tabela 3 abaixo, apresenta-se um resumo dos resultados encontrados, quando utilizando os controles de tendência linear temporal, controles de efeitos fixos de Estado_Ano e controles de efeitos fixos de Município. Para estabelecer uma base de comparabilidade entre as culturas, os resultados obtidos (impacto de produtividade em kg/ha) foram padronizados para representar impacto percentual relacionado à produtividade de cada cultura em 2020. Essa base de comparabilidade é relevante, dado que a escala de produtividade de culturas como a cana-de-açúcar é muito maior do que de grãos, por ser mais densa, produzindo mais quilogramas por hectare.

Conforme verificado nesta tabela meramente ilustrativa (resultados robustos são encontrados nos apêndices), os resultados obtidos foram condizentes com o esperado pelo presente trabalho. Temos relações negativas e positivas entre a produtividade das culturas analisadas e choques de temperatura e pluviosidade em relação às suas médias históricas. Nesse sentido, o somatório percentual de impacto sobre a produtividade, para desvios de temperatura, foi negativo, sugerindo que desvios de variáveis climáticas podem trazer impactos negativos para a produtividade, considerando o período de um ano.

A partir disso, temos a interpretação de que variações climáticas futuras podem trazer impactos negativos estatisticamente significativos para a produtividade de soja, milho e cana-de-açúcar.

Tabela 6: Resultados Econométricos das Regressões*


	Soja		Milho		Cana	
	<i>Desvio de Temperatura</i>	<i>Desvio de Pluviosidade</i>	<i>Desvio de Temperatura</i>	<i>Desvio de Pluviosidade</i>	<i>Desvio de Temperatura</i>	<i>Desvio de Pluviosidade</i>
Jan	0%	0%	0%	1%	0%	0%
Fev	-41%	2%	-40%	1%	12%	0%
Mar	24%	-1%	25%	0%	-37%	0%
Abr	0%	0%	-51%	0%	0%	0%
Mai	0%	1%	12%	0%	-22%	0%
Jun	0%	0%	-19%	1%	-7%	0%
Jul	7%	0%	14%	-1%	0%	0%
Ago	-19%	0%	-47%	0%	11%	0%
Set	21%	0%	50%	1%	11%	0%
Out	37%	-1%	12%	0%	-11%	0%
Nov	-56%	0%	0%	-1%	-10%	0%
Dez	18%	-1%	-11%	0%	21%	0%

Em base de produtividade média de 2020.

*Valores de 0,0% representam valores que não são estatisticamente significativos. Os demais valores são significativos com até 90% de confiança.

Uma curiosidade em nossos resultados foi a obtenção de resultados estatisticamente significativos nas regressões para soja para meses que não os meses tradicionais de safra. A Figura 4 indica quais seriam esses períodos a depender da região país. Dada sua sazonalidade, encontrar resultados estatisticamente significativos para os meses de junho a setembro para a produtividade da soja não era esperado. Cabe ressaltar, porém, que os meses com resultados mais relevantes para a soja, novembro e fevereiro, respectivamente – em valor absoluto – são justamente meses de auge de plantio e de auge de colheita na maior parte das regiões brasileiras.

Figura 4: Períodos de Safra - Soja




Fonte: CONAB, elaboração própria.

Uma possível explicação para a obtenção de resultados estatisticamente significativos em meses fora de safra poderia ser que eventuais choques climáticos que antecedam o período de colheita ou plantio podem também exercer influência sobre a produtividade da safra, dado que alteram diversas condições do solo (HOOGENBOOM, 2000).


Quanto ao milho, apesar de também ser uma cultura com sazonalidade, possui duas safras ao longo do ano. Isto é, o milho, rotacionado com a soja muitas vezes, é plantado e colhido mais de uma vez no período de um ano, conforme dados da Conab e exposto nas figuras 5 e 6. Em vista disso, encontrar estimadores estatisticamente significativos para quase todos os meses não contraria o período safra desta cultura.

Figura 5: Períodos de Safra - Milho (Primeira Safra)



Fonte: CONAB, elaboração própria.

Figura 6: Períodos de Safra - Milho (Segunda Safra)



Fonte: CONAB, elaboração própria.

A respeito da cana-de-açúcar, apesar de ser uma cultura temporária (que demanda o replantio pós-colheita), o intervalo entre o plantio e a colheita da cana muitas vezes dura mais do que 12 meses, de modo a se ter a cana no solo por períodos longos, justificando resultados estatisticamente significativos para mais de um mês.

Outro fator que chama atenção em relação aos parâmetros de interesse estimados é que os regressores de temperatura obtiveram resultados muito maiores. Esse achado vai de encontro com a vasta literatura de agrometeorologia, na qual há o consenso de que a temperatura do ar é a principal variável climática a regular a taxa de vegetação, germinação e reprodução das plantas (HODGES, 1991, BOOTE, 1991, HOOGENBOOM, 2000). Assim sendo, seus efeitos são mais relevantes sobre a produtividade agrícola das diferentes culturas, conforme confirmamos através de nosso modelo econométrico.

4.2 Projeções de Impacto de Produtividade

A partir dos coeficientes obtidos³³, de impacto de produtividade atrelados a desvios de condições climáticas, conforme elucidado no subcapítulo anterior, foi feita uma estimativa de qual seria o impacto dos 4 diferentes cenários delineados pelo IPCC de anomalias climáticas, SSP1-2.6, SSP2-4.5, SSP3-7.0 e SSP5-8.5, sob a produtividade agrícola nacional.

Para fazê-lo, estimamos qual seria o desvio percentual das condições climáticas projetadas, calculando o desvio entre a temperatura e pluviosidade projetada pelo IPCC, para cada cenário, em relação à média dos últimos 20 anos de temperatura e pluviosidade mensal – que estimamos ao longo deste trabalho. Basicamente, realizamos o mesmo processo realizado para construir os painéis das regressões, trocando as informações históricas por projeções do IPCC. Com isso, encontramos a projeção de desvios de temperatura e pluviosidade³⁴ para os próximos 80 anos. Assim, multiplicamos tais projeções pelos parâmetros de interesse estimados.

Uma limitação para nossas projeções é o nível de granularidade entre os dados projetados pelo IPCC que utilizamos como input – em 4 grandes regiões, conforme discutido nos capítulos anteriores – e o nível de granularidade de nossas médias históricas – inicialmente a nível de estação INMET, posteriormente interpolado espacialmente para nível municipal. Para contornar essa disparidade, foi feita uma média histórica de temperatura e pluviosidade por região, para encontrar o desvio médio por região, fornecendo as projeções dadas pelo IPCC. A partir disso, foi feita a relação os coeficientes das regressões estimadas – que nos indicam o impacto que o desvio climático exerce sobre a produtividade de uma determinada cultura – com os desvios climáticos projetados obtidos.

Os resultados obtidos, para os diferentes cenários, encontram-se no Apêndice E. Para analisar a distinção de trajetórias de impacto de produtividade entre as diferentes *reference regions* analisadas, cabe analisar as particularidades de cada região em relação a cada cultura, conforme descrito nas tabelas 7, 8 e 9.

³³ Para fins de projeção, foi utilizado o mesmo modelo econométrico que o apresentado nos capítulos anteriores, isto é, considerando efeitos-fixos de Município e Estado-Ano.

³⁴ o IPCC nos dá a temperatura e pluviosidade em si, encontramos uma estimativa de qual seria o desvio em relação à média histórica que calculamos para construção do painel da regressão.

Tabela 7: Comparação de Produção de Soja entre as *Reference Regions* - histórico 20 anos

	SES	SAM	NES	NSA
Área Plantada (Ha)	11,436,790	8,381,910	5,131,199	50,939
Valor (R\$ mil)	28,042,347	20,514,039	13,124,348	146,603
Quantidade (ton)	31,725,885	25,952,459	14,828,754	148,152
Produtividade (kg)	2,620	2,913	2,757	2,792

Fonte: elaboração própria, baseado em dados do IBGE - PAM.

Tabela 8: Comparação de Produção de Milho entre as *Reference Regions* - histórico 20 anos

	SES	SAM	NES	NSA
Área Plantada (Ha)	6,514,452	3,442,321	3,803,492	79,849
Valor (R\$ mil)	12,250,692	6,303,939	5,345,911	1,704,892
Quantidade (ton)	31,969,587	18,426,059	12,009,001	2,123,141
Produtividade (kg)	4,511	3,953	1,827	2,253

Fonte: elaboração própria, baseado em dados do IBGE - PAM.

Tabela 9: Comparação de Produção de Cana entre as *Reference Regions* - histórico 20 anos

	SES	SAM	NES	NSA
Área Plantada (Ha)	5,581,706	715,428	1,666,349	3,285
Valor (R\$ mil)	21,430,690	3,254,138	6,909,591	46,882
Quantidade (ton)	436,188,446	54,401,244	113,305,542	195,205
Produtividade (kg)	57,367	51,960	45,859	37,119

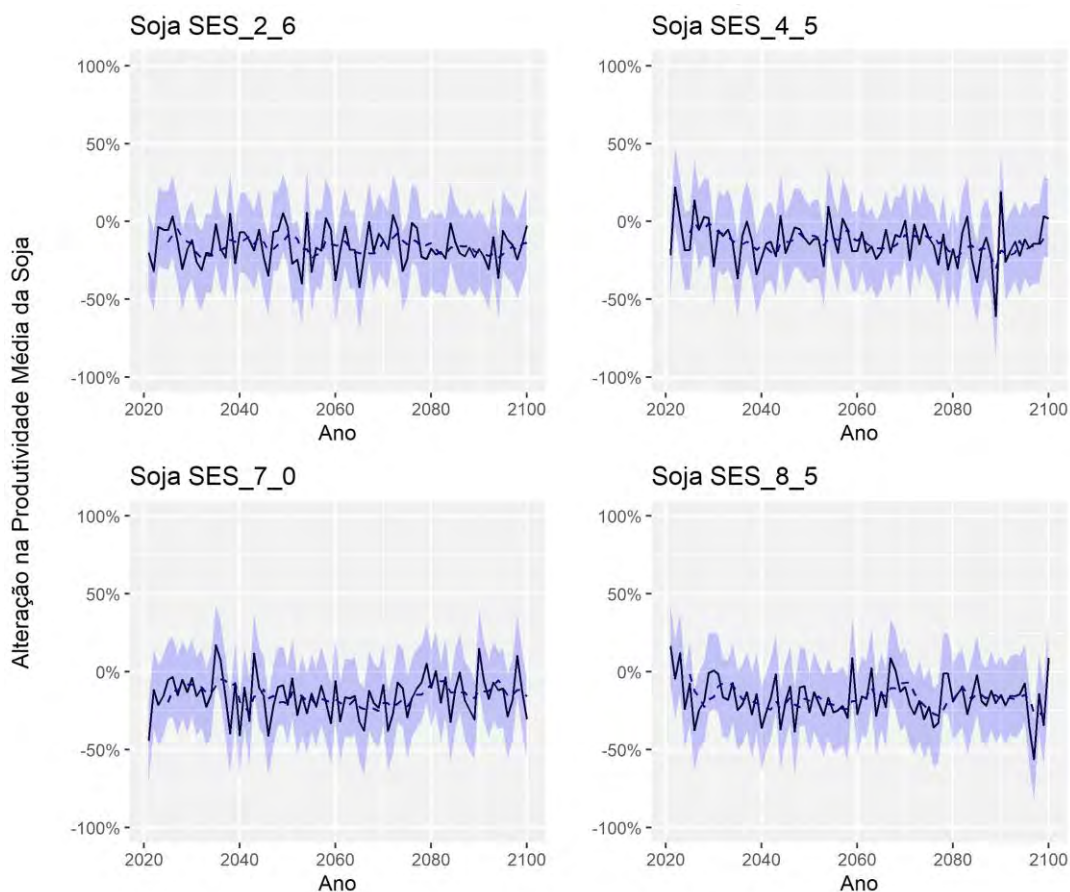
Fonte: elaboração própria, baseado em dados do IBGE - PAM.

Historicamente, a região SES respondeu pela maior área plantada para soja, milho e cana-de-açúcar no Brasil. Em termos de produtividade média, não há uma variação muito significativa entre as diferentes regiões para a soja. Por outro lado, as culturas de milho e de cana-de-açúcar apresentam uma amplitude maior de produtividade média regional – em ambas, as regiões NES e NSA apresentam produtividade média bem abaixo das demais regiões.

Em vista disso vamos analisar os resultados por cultura e por região, selecionando as duas principais regiões para cada cultura em termos de área plantada, conforme indicado previamente nas tabelas 7, 8 e 9. As análises foram feitas considerando um intervalo de confiança de 90% – em sombreado azul – e foram aplicadas médias móveis dos últimos 5 anos – linhas pontilhadas –, na tentativa de elucidar potenciais tendências.

Para a soja, as regiões de maior representatividade de acordo com o critério selecionado são SES e SAM – englobando estados tradicionais de plantação desta cultura como Goiás e Mato Grosso. As figuras 7 e 8 apresentam os resultados para essas regiões, por cenário do IPCC.

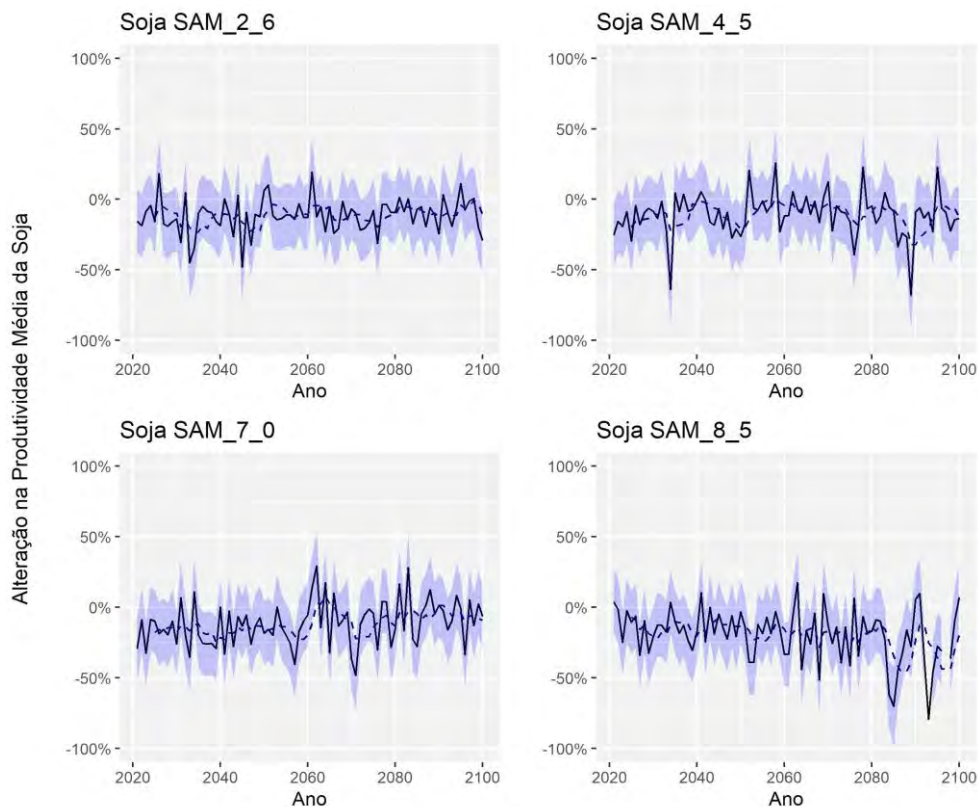
Figura 7: Projeção de Impacto (%) de Produtividade para Soja, região SES



* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Figura 8: Projeção de Impacto (%) de Produtividade para Soja, região SAM



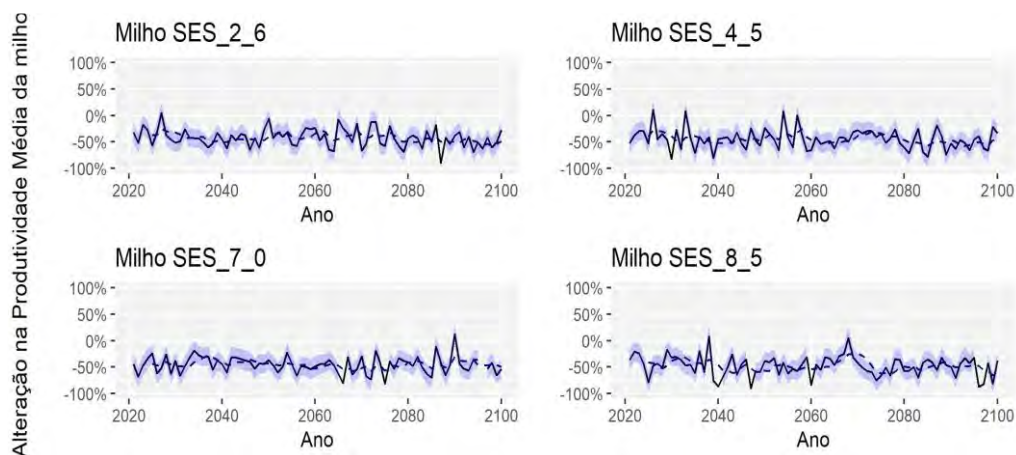
* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Os resultados encontrados para soja foram, em maioria, negativos. Na região SAM, é perceptível que as variações de produtividade se encontram mais negativas nos cenários SSP3-7.0 e SSP5-8.5. Os resultados ficaram na faixa de 25%, em média, de perda de produtividade para a soja, nas regiões descritas pelas figuras acima.

As figuras 9 e 10 trazem os resultados de impacto de produtividade projetado sobre o milho para as principais regiões em termos de área plantada.

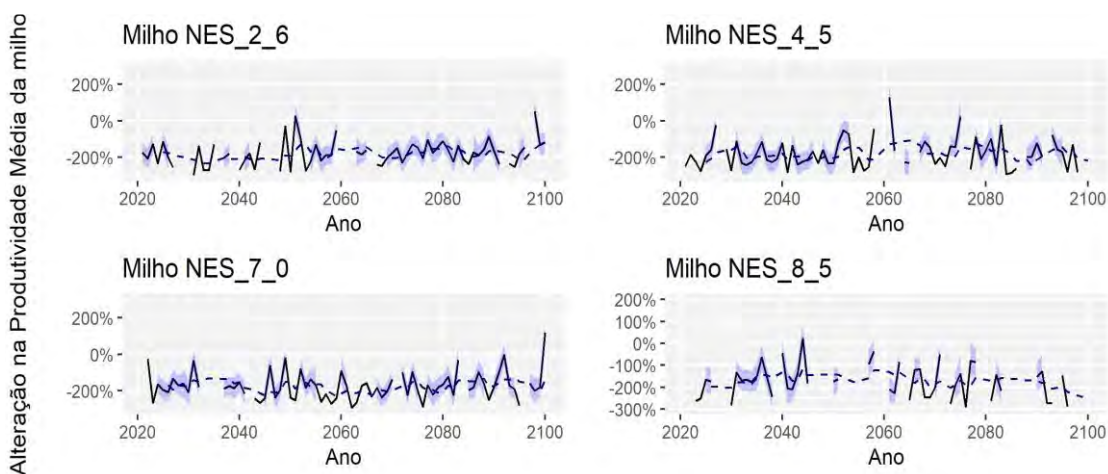
Figura 9: Projeção de Impacto (%) de Produtividade para Milho, região SES



* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Figura 10: Projeção de Impacto (%) de Produtividade para Milho, região NES

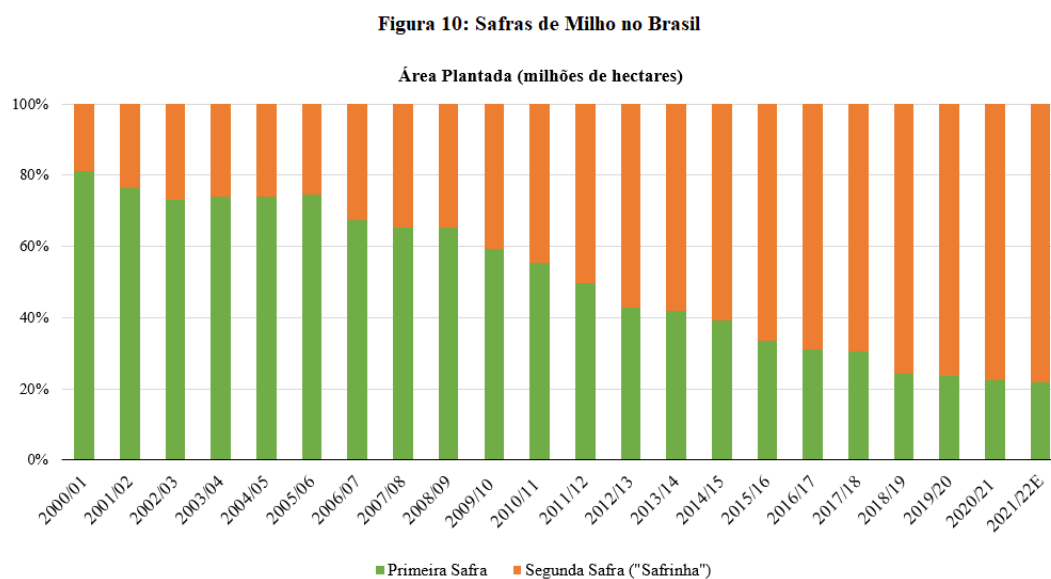


* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Para milho, obtivemos projeções de perdas percentuais de produtividade mais expressivas do que para soja, ficando em média em perdas de 50% de produtividade para a região SES e perdas de mais de 100% para a região NES. Uma possível explicação para isso pode ser a alta vulnerabilidade a condições climáticas averiguada na segunda safra de milho no Brasil – comumente chamada de “safrinha” – que hoje é responsável pela

maior parte da produção brasileira desta cultura, conforme Figura 10³⁵. Por ser feita “fora da época normal e em condições climáticas desfavoráveis”, é considerada uma safra “arriscada do ponto de vista agrônômico e, em princípio, fadada a permanecer marginal ou mesmo extinguir-se, foi denominada “safrinha”, (EMBRAPA)³⁶. Assim, pode-se pensar que a produtividade agrícola brasileira de milho esteja mais sujeita à variabilidade climática do que a soja.



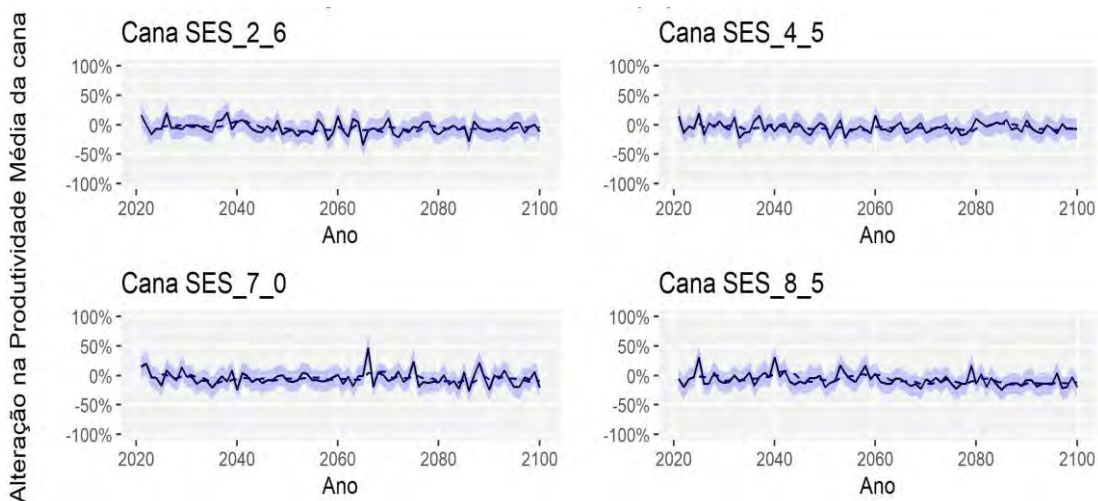
Fonte: CONAB, Série Histórica das Safras. Elaboração própria.

As figuras 11 e 12 reportam as trajetórias de impacto de produtividade sobre a cana-de-açúcar, para as duas regiões com maior área plantada desta cultura historicamente.

³⁵ CONAB, 2021: Série Histórica das Safras. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?start=20>. Acesso em: 20/11/2021.

³⁶ Conforme o EMBRAPA define: “O milho safrinha é definido como o milho de sequeiro cultivado extemporaneamente, de janeiro a abril, quase sempre depois da soja precoce, na região Centro-Sul brasileira, envolvendo basicamente os estados do Paraná, São Paulo, Goiás, Mato Grosso, Mato Grosso do Sul e, mais recentemente, Minas Gerais” (Disponível em: <https://www.agencia.cnptia.embrapa.br/gestor/milho/arvore/CONT000fya0krse02wx5ok0pvo4k3mp7ztkf.html>).

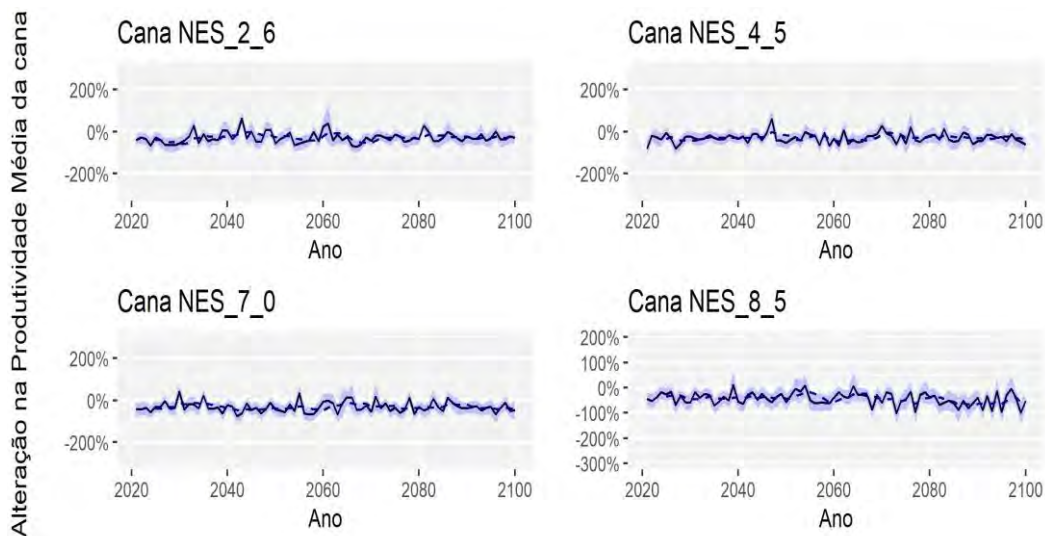
Figura 11: Projeção de Impacto (%) de Produtividade para Cana, região SES



* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Figura 12: Projeção de Impacto (%) de Produtividade para Cana, região NES



* Impacto percentual em relação à produtividade média da região em 2020.

Fonte: elaboração própria, através da ferramenta Rstudio.

Para cana-de-açúcar, obtivemos para a região SES impactos de produtividade que oscilam positiva e negativamente. Já para a região NES, encontramos resultados na faixa de -50%, semelhantes aos encontrados para a soja.

É relevante comentar que, nas projeções aqui realizadas, não foi considerado o possível aumento de produtividade ao longo dos próximos 80 anos. Há, historicamente,

um incremento de produtividade ao longo dos anos nas diferentes culturas agrícolas no Brasil³⁷. Nesse sentido, a Tabela 10 indica os incrementos de produtividade nas 3 culturas analisadas em diferentes intervalos de tempo, ficando historicamente em um CAGR abaixo de 5% para todas. Apesar de termos esta observação, nada garante que o incremento de produtividade nos próximos anos será de magnitude semelhante. Em vista disso, o presente trabalho optou por não fazer presunções acerca de qual seria o incremento de produtividade anual futuro.

Tabela 10: CAGR Produtividade			
	<i>Cana de Açúcar</i>	<i>Soja</i>	<i>Milho</i>
2000-2010	1.95%	2.26%	3.28%
2005-2015	1.03%	3.94%	4.35%
2010-2020	-0.50%	0.96%	2.19%

Fonte: elaboração própria a partir de dados do IBGE.

³⁷ Em nossa metodologia econométrica, controlamos esses efeitos históricos através da inclusão de efeitos-fixos Estado-Ano – os quais englobam efeitos-fixos de Ano.

5. CONCLUSÃO

Neste trabalho, resultados empíricos foram encontrados a respeito das duas hipóteses relevantes que buscamos testar: a existência de relação estatisticamente significativa entre variáveis climáticas e produtividade agrícola no Brasil; e, conseqüentemente, a existência de impactos potenciais sobre produtividade agrícola ocasionados pelas mudanças climáticas. Por meio de regressões em painel com efeitos-fixos, estimamos coeficientes de impacto de produtividade para desvios percentuais de temperatura e pluviosidade, em relação às médias históricas. Em seguida, estimamos quais seriam os impactos sobre produtividade, na presença de indicadores climáticos tais quais os cenários projetados pelo IPCC.

A partir dos resultados das regressões realizadas, com grau de confiança de até 90%, desvios de temperatura e pluviosidade impactam a produtividade agrícola no Brasil.

A avaliação qualitativa acerca desse impacto pode ser feita através da análise dos próprios coeficientes estimados: de maneira agregada, sugerem um impacto negativo, quanto a desvios de temperatura e positivos quanto a desvios de pluviosidade, conforme somatório dos valores mensais da Tabela 6, para as três culturas. Para soja, encontramos um somatório de -10,4% de impacto de desvio de temperatura sob a produtividade e +0,5% para pluviosidade. Para milho, encontramos -55,7% de impacto de temperatura e +1,2% de pluviosidade. Para cana-de-açúcar, -31,7% para temperatura e +0,7% para pluviosidade.

Outra contribuição deste trabalho para uma interpretação qualitativa acerca do impacto de desvio de variáveis climáticas sobre a produtividade agrícola brasileira, foi observar os resultados das projeções, a partir de cenários do IPCC. Por este método, os resultados encontrados são mais heterogêneos. A maioria das trajetórias projetadas demonstram perda de produtividade para soja, milho e cana-de-açúcar nos próximos 80 anos. Em especial, as regiões onde essas culturas possuem, historicamente, maior representatividade de área plantada, apresentaram resultados de perda de produtividade, exceto para cana-de-açúcar. Para a soja, as perdas ficaram na faixa de 25% para as regiões SES e SAM. Para o milho, observamos perdas na faixa de 50% para a região SES e de mais de 100% para a região NES – chegando a perdas de mais de 200% em alguns cenários. Para as trajetórias projetadas para a cana-de-açúcar, o impacto de produtividade oscilou entre valores positivos e negativos para a região SES e perdas na faixa de 50% para a região NES. Apesar dessas observações terem sido, em sua maioria, de projeção

de impacto negativo, cabe mencionar que algumas das regiões, de menor representatividade de terra plantada para as culturas analisadas, obtiveram trajetórias de ganho de produtividade. Este foi o caso da região NSA, que oscilou entre impactos de ganhos de produtividade na faixa de 25%, para as três culturas.

Os resultados obtidos a partir da análise qualitativa dos coeficientes das regressões indicam uma relação negativa entre desvios climáticos e produtividade agrícola. As projeções, em sua maioria, também refletem uma relação negativa entre mudanças climáticas e produtividade agrícola, exceto para algumas regiões, notavelmente para a região NSA.

É preciso reconhecer que temos algumas limitações no presente trabalho. Acerca dos impactos projetados, é importante salientar que foram estimados desvios projetados a níveis de agregação muito amplos, diferentemente da metodologia utilizada para encontrar os regressores econométricos. Nesse sentido, as projeções em si carecem de granularidade. Olhamos apenas 4 regiões e assumimos que todos os municípios englobados por elas teriam, no futuro, o mesmo nível de temperatura e pluviosidade. Em nossa própria metodologia, na estimação dos parâmetros de interesse, foram utilizadas informações a nível municipal – inclusive houve todo um trabalho de interpolação espacial para chegar nesse nível de granularidade para informações climáticas, dado que não há disponibilidade de dados climáticos a nível de município.

Os coeficientes encontrados em nossas regressões e as trajetórias de impacto de produtividade projetadas para os próximos 80 anos trazem evidências empíricas para a hipótese que buscamos testar nesta monografia: desvios de variáveis climáticas possuem impacto sobre a produtividade agrícola no Brasil. Quanto à avaliação qualitativa desta hipótese, obtivemos resultados que indicam, em sua maioria, uma relação negativa.

6. REFERÊNCIAS BIBLIOGRÁFICAS

Anderson, T. (ed.), 2015: *USDA Midwest and Northern Forests Regional Climate Hub: Assessment of Climate Change 15 Vulnerability and Adaptation and Mitigation Strategies*. U.S. Department of Agriculture, USA, 55 pp. Disponível em: <https://mrcc.purdue.edu/events/SpecialtyCrop/docs/MidwestRegionVulnerabilityAssesment3_20_2015_0.pdf>. Acesso em: 26/11/2021.

ANDREW, Robie. *It's getting harder and harder to limit ourselves to 2°C*. CICERO Center for International Climate Research, 15 jan. 2020. Disponível em: <https://folk.universitetetioslo.no/roberan/t/global_mitigation_curves.shtml>. Acesso em: 25 jun. 2021.

Aydinalp, C. & Cresser, M.S. 2008. *The effects of global climate change on agriculture*. American-Eurasian journal of agricultural and environmental science, 3: 672-676.

BALTAGI, B. *Econometric analysis of panel data*. 4th. ed. [S.l.]: John Wiley & Sons, 2008.

Boote, K.J., Loomis, R.S. (Eds.), 1991. *Modeling crop photosynthesis — from biochemistry to canopy*. CSSA Special Publication Number 19. Crop Science Society of America, Madison, WI.

CONAB, 2021. *Acompanhamento da Safra Brasileira: Grãos Safra 2020/21 6º Levantamento*. p. 1-106, março 2021. Publicação integrante do Observatório Agrícola. Disponível em: <<http://www.conab.gov.br>>. Acesso em: 29/11/2021.

CHANDIO, A. A., et al. *Short and long-run impacts of climate change on agriculture: an empirical evidence from China*. International Journal of Climate Change Strategies and Management. 2020b. Disponível em: <<https://www.emerald.com>>. Acesso em: 27/11/2021.

EMBRAPA, 2003. **Soja na Alimentação de Bovinos.** Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/104635/1/Soja-na-alimentacao-de-bovinos.pdf>>. Acesso em: 26/11/2021

EMBRAPA, 2005. **Agricultura de Precisão: manejo da variabilidade espacial e temporal dos solos e culturas.** Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/489734/1/Doc46.pdf>>. Acesso em: 26/11/2021.

EMBRAPA, 2020. **O Agro no Brasil e no Mundo: uma síntese do período de 2000 a 2020.** Disponível em: <<https://www.embrapa.br/documents/10180/62618376/O+AGRO+NO+BRASIL+E+N+O+MUNDO.pdf/41e20155-5cd9-f4ad-7119-945e147396cb>>. Acesso em: 26/11/2021.

FAOSTAT, **Crops and Livestock Products.** Disponível em: <<http://www.fao.org/faostat/en/#data>>. Acesso em: 20/10/2021

FAOSTAT, **World Food Situation.** Disponível em: <<https://www.fao.org/worldfoodsituation/csdb/en/>>. Acesso em: 26/11/2021

FAO. 2021. **Food Outlook – Biannual Report on Global Food Markets.** Food Outlook, November 2021. Rome.

HODGES, T. (Ed.), 1991. *Predicting Crop Phenology.* CRC Press, Boca Raton, FL.

HOOGENBOOM, G. *Contribution of agrometeorology to the simulation of crop production and its application.* Agricultural and Forest Meteorology, 103, 137-157, 2000.

IBGE. **Produto Agrícola Municipal – Tabela 5457.** Disponível em: <<https://sidra.ibge.gov.br/tabela/5457>>. Acesso em: 25/06/2021.

IEA, 2021. **Net Zero by 2050: A Roadmap for the Global Energy Sector**

INMET: **Banco de Dados Meteorológicos**. Disponível em: [<https://portal.inmet.gov.br/>](https://portal.inmet.gov.br/). Acesso em: 01/06/2021

INMET, 2009. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Organizador José Eduardo B. A Monteiro - Brasília, DF. 530 p.: il

IPCC, 2021: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press. In Press.

IPCC. *Impacts of 1.5°C of Global Warming on Natural and Human Systems: Chapter 3*. 2018. Disponível em: https://www.ipcc.ch/site/assets/uploads/sites/2/2019/06/SR15_Chapter3_Low_Res.pdf >. Acesso em: 25/06/2021.

IPCC. **Official GitHub repository for IPCC-WG1**. Disponível em: <https://github.com/IPCC-WG1>>. Acesso em: 01/11/2021.

IPCC. *Regional fact sheet – Central and South America*. Disponível em: https://www.ipcc.ch/report/ar6/wg1/downloads/factsheets/IPCC_AR6_WGI_Regional_Fact_Sheet_Central_and_South_America.pdf>. Acesso em: 30/11/2021.

MESQUITA, R. **Uma Introdução à regressão com dados de painel**. Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP – UFPE). Disponível em: <https://periodicos.ufpe.br/revistas/politicahoje/article/viewFile/246522/38645>>. Acesso em: 25/11/2021

PEREIRA, Antônio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo César. **Agrometeorologia: fundamentos e aplicações práticas**. [S.l: s.n.], 2002.

REINALDO, L. 2017: **Estimação Clássica e Bayesiana para Dados em Painel**. Universidade de Brasília. Instituto de Ciências Exatas. Disponível em: <https://repositorio.unb.br/bitstream/10482/24516/1/2017_LucianaMouraReinaldo.pdf>. Acesso em: 28/11/2021.

ROMEIRO, Ademar Ribeiro, **Desenvolvimento Sustentável: uma perspectiva econômico – ecológica**, em Revista Estudos Avançados 74, vol 26, n 74, jan/abr 2012, USP.

SOUZA, Bruno Santos de. **Mudanças climáticas no Brasil: efeitos sistêmicos sobre a economia brasileira provenientes de alterações na produtividade agrícola**. 2018. Dissertação (Mestrado em Teoria Econômica) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2018. doi:10.11606/D.12.2018.tde-15102018-113337. Acesso em: 2021-09-19.

The Economist, 2021. ***Bunged Up: How Green Bottlenecks threaten the Clean Energy Business***. Disponível em: <<https://www.economist.com/leaders/2021/06/12/how-green-bottlenecks-threaten-the-clean-energy-business>>. Acesso em: 12/06/2021

USP, 2016. **Análise Multivariada Aplicada à Contabilidade**. Disponível em: <https://edisciplinas.usp.br/pluginfile.php/2113462/mod_resource/content/1/An%C3%A1liseMultivariada-Aula08.pdf>. Acesso em: 01/11/2021.

Vandyck, T. et al., 2018: ***Air quality co-benefits for human health and agriculture counterbalance costs to meet Paris Agreement pledges***. Nature Communications. Disponível em: <<https://www.nature.com/articles/s41467-018-06885-9.pdf>>. Acesso em: 27/11/2021.

7. APÊNDICES

Apêndice A

Evolução Anual da Produtividade (kg/Ha)						
Ano	<i>Soja</i>		<i>Milho</i>		<i>Cana-de-Açúcar</i>	
	Produtividade	YoY	Produtividade	YoY	Produtividade	YoY
2000	2.173	NA	2.093	NA	43.456	NA
2001	2.433	12,0%	2.259	7,9%	44.594	2,6%
2002	2.325	-4,4%	2.269	0,5%	46.780	4,9%
2003	2.585	11,1%	2.543	12,1%	48.109	2,8%
2004	2.120	-18,0%	2.431	-4,4%	48.893	1,6%
2005	1.912	-9,8%	2.262	-7,0%	48.440	-0,9%
2006	2.272	18,8%	2.403	6,3%	50.658	4,6%
2007	2.616	15,1%	2.680	11,5%	51.879	2,4%
2008	2.571	-1,7%	2.809	4,8%	53.357	2,8%
2009	2.450	-4,7%	2.640	-6,0%	53.285	-0,1%
2010	2.779	13,4%	2.986	13,1%	53.740	0,9%
2011	2.917	5,0%	3.067	2,7%	54.004	0,5%
2012	2.407	-17,5%	3.136	2,2%	52.345	-3,1%
2013	2.865	19,0%	3.424	9,2%	54.237	3,6%
2014	2.659	-7,2%	3.340	-2,5%	53.353	-1,6%
2015	2.926	10,1%	3.614	8,2%	54.237	1,7%
2016	2.909	-0,6%	3.416	-5,5%	54.193	-0,1%
2017	3.253	11,8%	3.810	11,6%	50.518	-6,8%
2018	3.252	0,0%	3.680	-3,4%	49.742	-1,5%
2019	3.053	-6,1%	3.831	4,1%	50.564	1,7%
2020	3.088	1,1%	3.791	-1,0%	50.848	0,6%

Fonte: elaboração própria a partir de dados do IBGE.

Apêndice B1: Resultados Econométricos - Desvio de Temperatura - Soja

	<i>Dependent variable:</i>			
	Soja_Produtividade			
	(1)	(2)	(3)	(4)
jan_temp_dev	1,370.8*** (134.4)	1,358.3*** (115.4)	-463.1*** (127.9)	-225.7 (163.7)
fev_temp_dev	-942.8*** (118.5)	-965.6*** (101.2)	-325.2** (135.6)	-1,272.8*** (164.6)
mar_temp_dev	-2,018.3*** (108.2)	-2,074.3*** (92.3)	-1,956.5*** (111.7)	734.1*** (163.1)
abr_temp_dev	-536.2*** (80.5)	-444.4*** (68.7)	1,455.0*** (76.8)	-33.4 (128.4)
mai_temp_dev	1,950.4*** (71.6)	1,895.9*** (61.0)	85.5 (75.4)	-109.4 (108.6)
jun_temp_dev	-1,920.7*** (56.8)	-1,878.4*** (48.4)	-591.8*** (55.7)	29.5 (100.3)
jul_temp_dev	832.3*** (52.9)	879.4*** (45.1)	476.5*** (50.3)	222.1** (88.5)
ago_temp_dev	-1,935.2*** (53.4)	-1,925.1*** (45.5)	-612.8*** (55.1)	-591.1*** (96.4)
set_temp_dev	2,135.7*** (50.1)	2,127.9*** (42.8)	1,192.9*** (58.8)	633.2*** (97.0)
out_temp_dev	2,392.1*** (91.7)	2,321.8*** (78.1)	1,630.7*** (91.1)	1,128.6*** (128.8)
nov_temp_dev	-4,135.8*** (117.9)	-4,057.5*** (100.6)	-3,441.0*** (116.1)	-1,718.6*** (155.8)
dez_temp_dev	1,719.8*** (121.2)	1,660.1*** (103.5)	837.1*** (108.9)	542.6*** (142.3)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado- Ano	Não	Não	Não	Sim
Observations	37,749	37,749	37,749	37,749
R ²	0.2	0.3	0.4	0.6

Note:

* p<0.1; ** p<0.05; *** p<0.01

Apêndice B2: Resultados Econométricos - Desvio de Pluviosidade - Soja

	<i>Dependent variable:</i>			
	Soja_Produtividade			
	(1)	(2)	(3)	(4)
jan_pluv_dev	109.3*** (7.5)	112.5*** (6.4)	62.6*** (5.8)	-6.9 (6.5)
fev_pluv_dev	123.8*** (7.1)	119.3*** (6.1)	115.8*** (5.7)	72.5*** (6.6)
mar_pluv_dev	-20.9*** (7.1)	-21.1*** (6.1)	-45.7*** (5.9)	-21.7*** (6.3)
abr_pluv_dev	-7.9 (5.6)	-9.9** (4.8)	33.6*** (5.1)	10.0* (5.6)
mai_pluv_dev	49.2*** (4.7)	54.7*** (4.0)	11.1*** (4.3)	17.3*** (4.7)
jun_pluv_dev	-22.2*** (3.5)	-19.6*** (3.0)	2.3 (3.1)	-2.8 (3.8)
jul_pluv_dev	-45.8*** (2.9)	-39.5*** (2.5)	-16.7*** (2.6)	2.7 (3.4)
ago_pluv_dev	16.7*** (3.4)	18.1*** (2.9)	2.2 (2.9)	-14.7*** (3.6)
set_pluv_dev	-24.5*** (4.9)	-25.7*** (4.2)	-13.1*** (4.2)	10.5** (5.0)
out_pluv_dev	42.7*** (6.3)	42.4*** (5.4)	12.2** (5.2)	-25.7*** (6.0)
nov_pluv_dev	22.6*** (6.4)	16.7*** (5.4)	-33.9*** (5.3)	-3.6 (6.3)
dez_pluv_dev	3.7 (7.0)	12.1** (6.0)	-11.2* (5.7)	-33.0*** (6.3)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado-Ano	Não	Não	Não	Sim
Observations	37,749	37,749	37,749	37,749
R ²	0.2	0.3	0.4	0.6

Note:

*p<0.1; **p<0.05; ***p<0.01

Apêndice C1: Resultados Econométricos - Desvio de Temperatura - Milho

	<i>Dependent variable:</i>			
	Milho_Produtividade			
	(1)	(2)	(3)	(4)
jan_temp_dev	3,340.9*** (307.5)	3,242.3*** (142.4)	1,241.8*** (144.5)	161.1 (200.5)
fev_temp_dev	-1,632.5*** (294.4)	-1,703.0*** (136.3)	-1,403.8*** (155.4)	-1,501.0*** (204.4)
mar_temp_dev	-6,265.3*** (294.2)	-6,526.3*** (136.2)	-4,685.2*** (151.7)	939.9*** (236.9)
abr_temp_dev	-958.4*** (218.9)	-1,256.8*** (101.3)	1,521.0*** (110.6)	-1,941.4*** (205.2)
mai_temp_dev	3,185.9*** (202.5)	2,866.1*** (93.7)	532.5*** (104.1)	448.3*** (171.5)
jun_temp_dev	-2,621.6*** (149.8)	-2,565.3*** (69.4)	-1,083.7*** (73.3)	-713.2*** (129.4)
jul_temp_dev	801.3*** (152.5)	803.3*** (70.6)	776.7*** (71.8)	528.7*** (136.9)
ago_temp_dev	-3,040.1*** (150.6)	-2,857.8*** (69.7)	-1,068.8*** (78.1)	-1,795.0*** (146.8)
set_temp_dev	5,253.6*** (146.9)	5,021.4*** (68.0)	3,279.7*** (78.3)	1,881.4*** (146.4)
out_temp_dev	2,790.8*** (239.1)	2,934.8*** (110.7)	723.8*** (118.5)	459.5** (180.1)
nov_temp_dev	-5,008.6*** (285.7)	-4,517.2*** (132.3)	-2,930.8*** (142.6)	-219.2 (201.0)
dez_temp_dev	2,178.9*** (297.9)	2,253.1*** (137.9)	290.9** (144.9)	-417.0** (192.7)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado-Ano	Não	Não	Não	Sim
Observations	92,358	92,358	92,358	92,358
R ²	0.05	0.2	0.3	0.4

Note:

*p<0.1; **p<0.05; ***p<0.01

Apêndice C2: Resultados Econométricos - Desvio de Pluviosidade - Milho

	<i>Dependent variable:</i>			
	Milho_Produtividade			
	(1)	(2)	(3)	(4)
jan_pluv_dev	79.6*** (12.0)	71.2*** (5.6)	98.7*** (5.7)	27.1*** (7.4)
fev_pluv_dev	25.0* (14.9)	7.7 (6.9)	32.6*** (6.6)	25.7*** (7.8)
mar_pluv_dev	-33.0** (15.2)	2.1 (7.0)	-16.0** (6.9)	-0.2 (8.3)
abr_pluv_dev	-45.4*** (13.2)	-17.4*** (6.1)	102.2*** (6.2)	-2.5 (7.2)
mai_pluv_dev	91.3*** (10.8)	117.6*** (5.0)	62.2*** (5.2)	18.7*** (6.2)
jun_pluv_dev	64.0*** (8.7)	35.7*** (4.0)	56.8*** (4.0)	27.5*** (4.9)
jul_pluv_dev	-88.9*** (7.2)	-83.2*** (3.3)	-24.4*** (3.5)	-32.6*** (4.5)
ago_pluv_dev	-25.4*** (8.0)	-25.9*** (3.7)	8.3** (3.7)	-3.0 (4.7)
set_pluv_dev	31.0*** (9.0)	12.7*** (4.2)	37.3*** (4.1)	22.9*** (5.1)
out_pluv_dev	15.8* (9.6)	20.9*** (4.4)	-11.9*** (4.3)	-16.5*** (5.2)
nov_pluv_dev	53.0*** (11.2)	29.9*** (5.2)	-27.2*** (5.1)	-26.3*** (6.2)
dez_pluv_dev	51.5*** (12.5)	50.0*** (5.8)	5.3 (5.7)	-10.9 (6.8)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado-Ano	Não	Não	Não	Sim
Observations	92,358	92,358	92,358	92,358
R ²	0.05	0.2	0.3	0.4

Note:

*p<0.1; **p<0.05; ***p<0.01

Apêndice D1: Resultados Econométricos - Desvio de Temperatura - Cana

	<i>Dependent variable:</i>			
	Cana_Produtividade			
	(1)	(2)	(3)	(4)
jan_temp_dev	-16,401.9*** (3,594.1)	-16,665.6*** (1,783.0)	-10,562.3*** (1,993.1)	1,780.6 (2,868.7)
fev_temp_dev	8,544.4** (3,410.2)	5,516.0*** (1,686.2)	-2,776.4 (2,117.7)	6,160.6** (2,879.3)
mar_temp_dev	-28,933.6*** (3,392.0)	-14,505.4*** (1,687.5)	-20,118.8*** (2,061.6)	-19,042.5*** (3,375.6)
abr_temp_dev	2,357.3 (2,508.4)	7,432.4*** (1,240.0)	6,193.7*** (1,484.2)	2,885.2 (2,902.0)
mai_temp_dev	-9,060.6*** (2,306.1)	-15,764.8*** (1,142.4)	-6,615.9*** (1,396.6)	-11,066.5*** (2,394.7)
jun_temp_dev	-15,235.2*** (1,719.4)	-8,261.5*** (851.6)	-6,729.0*** (976.2)	-3,372.9* (1,833.0)
jul_temp_dev	15,459.3*** (1,731.7)	11,576.5*** (856.5)	7,897.4*** (945.5)	2,769.6 (1,892.6)
ago_temp_dev	3,193.1* (1,730.7)	3,732.1*** (855.9)	752.3 (1,057.5)	5,767.4*** (2,052.7)
set_temp_dev	13,377.3*** (1,666.2)	4,792.6*** (826.5)	13,934.2*** (1,054.9)	5,539.4*** (2,004.6)
out_temp_dev	-7,100.6** (2,761.6)	-10,234.2*** (1,366.6)	-6,405.6*** (1,609.7)	-5,511.9** (2,544.1)
nov_temp_dev	11,151.4*** (3,321.5)	12,696.5*** (1,645.3)	2,274.8 (1,955.9)	-5,223.5* (2,892.3)
dez_temp_dev	6,952.1** (3,532.4)	-888.1 (1,751.7)	4,744.8** (2,018.2)	10,656.3*** (2,822.1)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado-Ano	Não	Não	Não	Sim
Observations	63,351	63,351	63,351	63,351
R ²	0.01	0.03	0.1	0.2

Note:

*p<0.1; **p<0.05; ***p<0.01

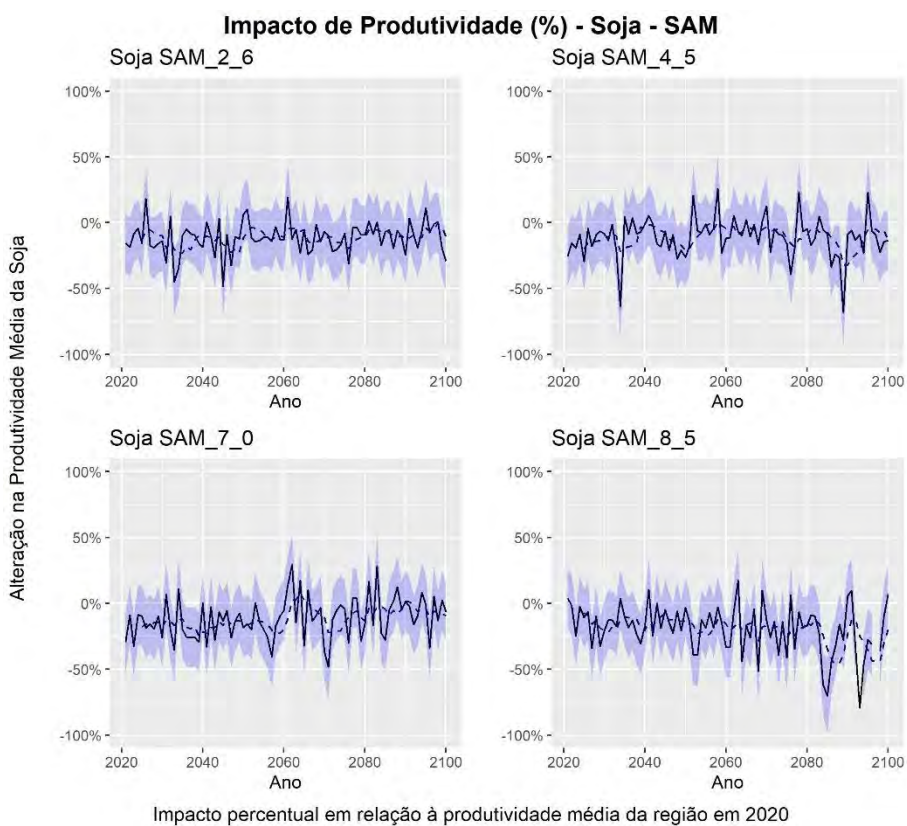
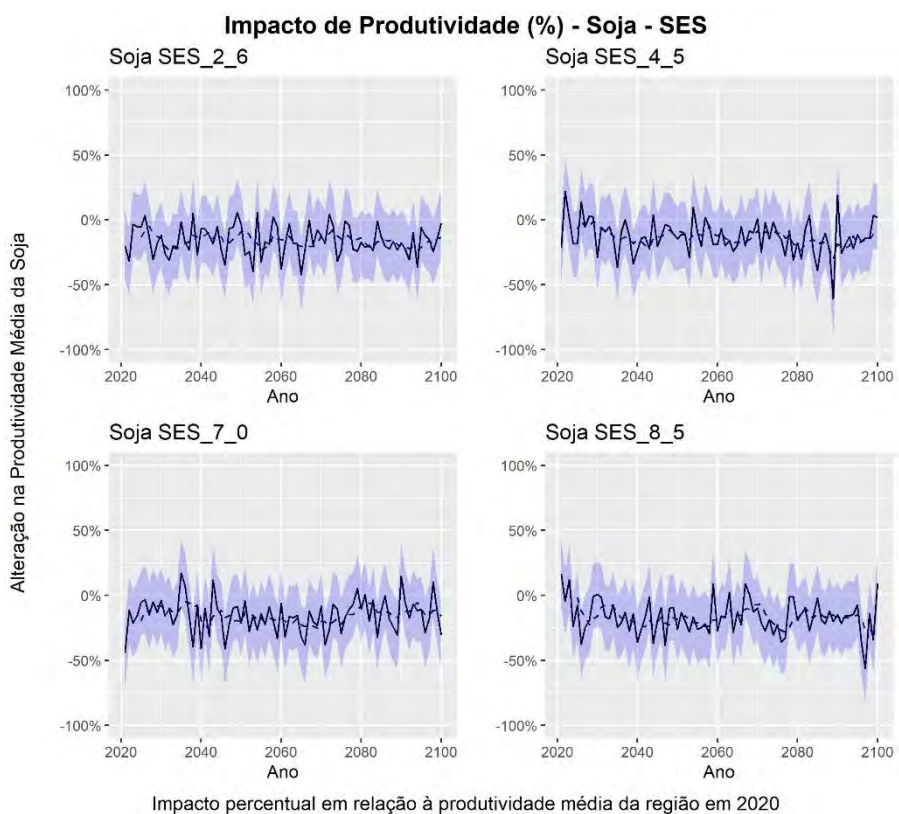
Apêndice D2: Resultados Econométricos - Desvio de Pluviosidade - Cana

	<i>Dependent variable:</i>			
	Cana_Produtividade			
	(1)	(2)	(3)	(4)
jan_pluv_dev	741.1*** (155.8)	756.2*** (77.3)	879.6*** (82.9)	118.0 (109.4)
fev_pluv_dev	-535.6*** (177.9)	-302.4*** (88.3)	-266.0*** (89.8)	210.4* (112.1)
mar_pluv_dev	363.4** (184.4)	286.2*** (91.4)	1.5 (96.4)	-6.4 (119.0)
abr_pluv_dev	-281.9* (153.5)	167.6** (76.0)	10.9 (82.9)	-144.4 (100.6)
mai_pluv_dev	616.6*** (128.3)	358.7*** (63.7)	327.0*** (71.2)	149.3* (89.3)
jun_pluv_dev	158.2 (99.7)	72.4 (49.5)	222.0*** (53.8)	106.8 (68.4)
jul_pluv_dev	61.0 (82.7)	73.7* (41.0)	-72.6 (47.4)	-173.1*** (64.1)
ago_pluv_dev	-736.0*** (94.0)	-509.4*** (46.7)	-216.1*** (51.0)	1.6 (66.2)
set_pluv_dev	3.0 (112.8)	-49.2 (56.0)	-146.5** (59.9)	-94.9 (78.5)
out_pluv_dev	-91.0 (122.7)	-11.6 (61.3)	-111.8* (64.3)	102.2 (83.1)
nov_pluv_dev	532.4*** (146.4)	475.7*** (72.9)	321.6*** (76.6)	183.7* (98.4)
dez_pluv_dev	205.7 (159.5)	-20.7 (79.2)	-232.7*** (83.3)	-140.4 (104.0)
EF Município	Não	Sim	Sim	Sim
EF Ano	Não	Não	Sim	Não
EF Estado-Ano	Não	Não	Não	Sim
Observations	63,351	63,351	63,351	63,351
R ²	0.01	0.03	0.1	0.2

Note:

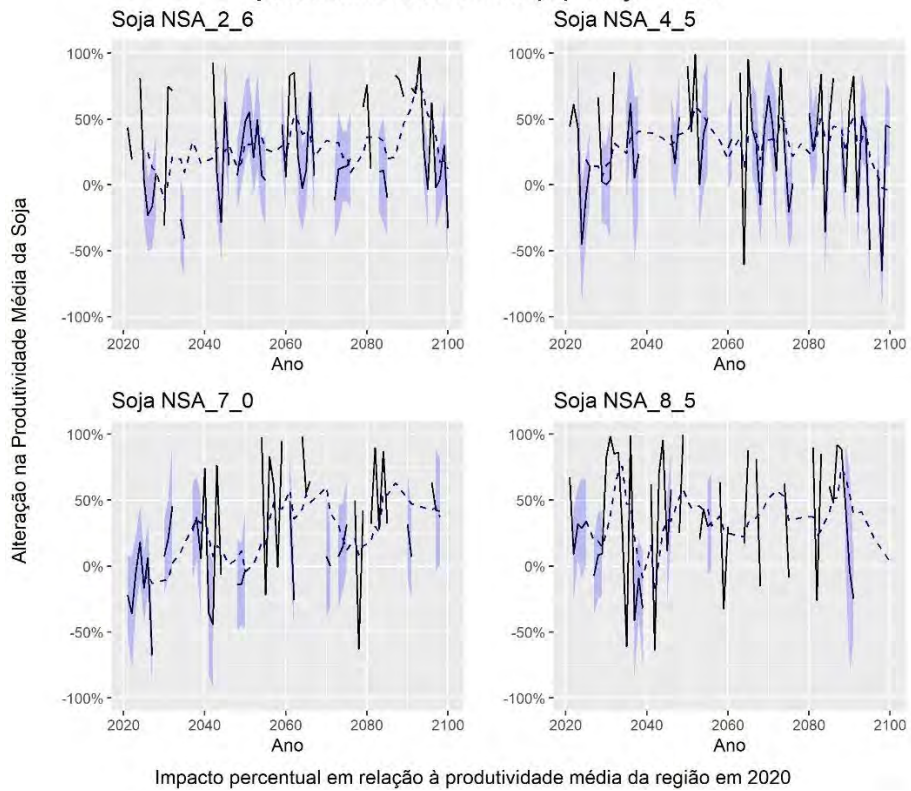
* p<0.1; ** p<0.05; *** p<0.01

Apêndice E1

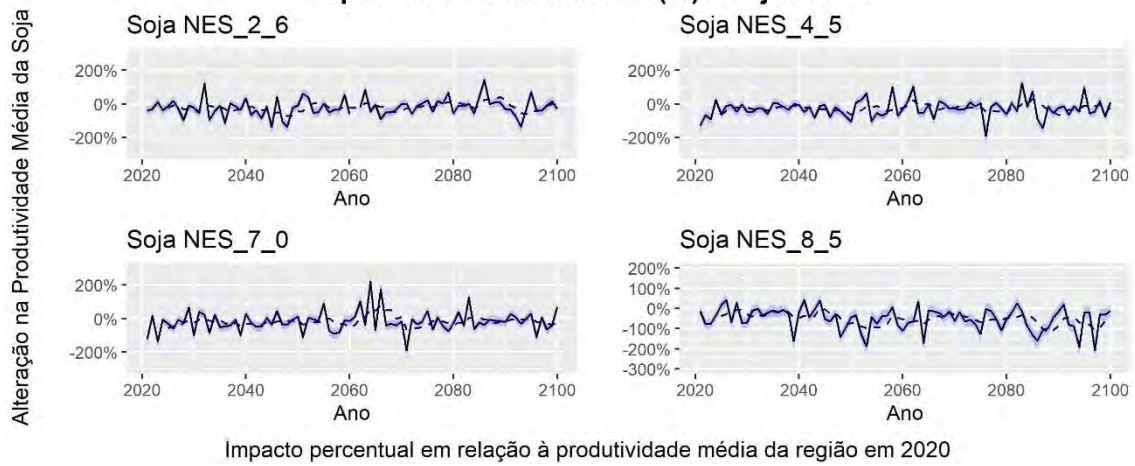


Apêndice E1



Impacto de Produtividade (%) - Soja - NSA





Impacto de Produtividade (%) - Soja - NES





Apêndice E2



Apêndice E2



Apêndice E3



Apêndice E3

