

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Geociências
Programa de Pós-graduação em Análise e Modelagem de Sistemas Ambientais

Argemiro Teixeira Leite Filho

**INTERAÇÕES ENTRE DESMATAMENTO, MUDANÇAS CLIMÁTICAS E
PRODUÇÃO AGRÍCOLA NO CERRADO E NA AMAZÔNIA BRASILEIRA**

Belo Horizonte
2022

Argemiro Teixeira Leite Filho

**INTERAÇÕES ENTRE DESMATAMENTO, MUDANÇAS CLIMÁTICAS E
PRODUÇÃO AGRÍCOLA NO CERRADO E NA AMAZÔNIA BRASILEIRA**

Versão final

Tese apresentada ao Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Análise e Modelagem de Sistemas Ambientais.

Orientador: Prof. Dr. Britaldo Silveira Soares Filho

Coorientador: Prof. Dr. Ubirajara de Oliveira

Belo Horizonte
2022

L533i
2022

Leite Filho, Argemiro Teixeira.

Interações entre desmatamento, mudanças climáticas e produção agrícola no cerrado e na Amazônia Brasileira [manuscrito] / Argemiro Teixeira Leite Filho. – 2022.
162 f., enc.: il. (principalmente color.)

Orientador: Britaldo Silveira Soares Filho.

Coorientador: Ubirajara de Oliveira.

Tese (doutorado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2022.

Área de concentração: Análise, Modelagem e Gestão de Sistemas Ambientais.

Bibliografia: 145-154.

Inclui glossário.

1. Modelagem de dados – Aspectos ambientais – Teses. 2. Solo – Uso – Brasil – Teses. 3. Soja – Teses. 4. Milho – Teses. I. Soares-Filho, Britaldo Silveira. II. Oliveira, Ubirajara de. III. Universidade Federal de Minas Gerais. Instituto de Geociências. IV. Título.

CDU: 911.2:519.6(81)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS

FOLHA DE APROVAÇÃO

INTERAÇÕES ENTRE DESMATAMENTO, MUDANÇAS CLIMÁTICAS E PRODUÇÃO AGRÍCOLA NO CERRADO E NA AMAZÔNIA BRASILEIRA.

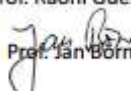
ARGEMIRO TEIXEIRA LEITE FILHO

Tese de doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS, como requisito para obtenção do grau de Doutor em ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS, área de concentração ANÁLISE, MODELAGEM E GESTÃO DE SISTEMAS AMBIENTAIS.

Prof. Britaldo Silveira Soares Filho - Orientador (UFMG)

Prof. Ubirajara de Oliveira (UFMG)

Prof. Raoni Guerra Lucas Rajão (UFMG)


Prof. Jan Börner (Universität Bonn)

Prof. Luciana Vanni Gatti (Instituto Nacional de Pesquisas Espaciais)

Belo Horizonte, 29 de setembro de 2022.



Documento assinado eletronicamente por **Britaldo Silveira Soares Filho**, **Membro**, em 14/10/2022, às 07:03, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luciana Vanni Gatti**, **Usuária Externa**, em 17/10/2022, às 15:37, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ubirajara de Oliveira**, **Usuário Externo**, em 18/10/2022, às 12:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Raoni Guerra Lucas Rajao**, **Professor do Magistério Superior**, em 21/11/2022, às 15:23, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Dedico aos meus pais Argemiro e Valmisa,
pelo amor infinito e apoio incessante.

AGRADECIMENTOS

Mais um ciclo se encerra e a palavra para este momento é gratidão.

A Deus, Alá, Krishna, Jeová, Oxum, ou alguma outra denominação como se queira chamar a inteligência suprema que rege o universo. Agradeço por ter me sustentado. Esta tese foi construída em grande parte durante a pandemia de COVID-19, mesmo diante dos percalços e tragédias, agradeço ainda mais por proteger os meus.

Reservo profunda gratidão à minha família, em especial, aos meus pais, irmãos, sobrinhos e minha companheira de quatro patas, pelo incessante amor, conforto e encorajamento.

À Universidade Federal de Minas Gerais, em especial ao Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais, pelo acolhimento e formação;

Ao Prof. Dr. Britaldo Soares Filho, pela confiança, orientação presente, pelas oportunidades e pela liberdade de pensar;

Ao Prof. Dr. Ubirajara Oliveira pelos conselhos, trocas de experiências e longos papos sobre estatística;

Aos membros do Centro de Sensoriamento Remoto, pelo acolhimento, em particular, à Amanda, Bárbara, Juliana e William pela solicitude e atenção;

À psicóloga Valéria, que com seu profissionalismo e competência me acompanhou por grande parte deste processo e me preparou para este e outros desafios.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos;

Ao Centro de Inteligência Territorial (CIT), pela contrapartida no desenvolvimento da pesquisa;

Que o novo ciclo se inicie com esperança.

“Todas as vitórias ocultam uma abdicação.”

- *Simone de Beauvoir* –

RESUMO

Espera-se que a produção agrícola brasileira continue aumentando em resposta à crescente demanda global por alimentos e biocombustíveis. Entretanto, a agricultura é um dos setores mais suscetíveis às variações climáticas. Neste contexto, a devastação dos biomas Amazônia (AM) e Cerrado (CE) gera preocupação porque interfere no clima local e regional, além de contribuir com a emissão de Gases de Efeito Estufa que intensificam as mudanças climáticas globais. Partindo desta problemática, esta tese investiga como as mudanças climáticas regionais (associadas ao desmatamento) afetam a produtividade da soja, milho e pastagens na AM Brasileira e CE. No primeiro capítulo avaliamos a perda de vegetação nativa e a redução da precipitação em pixels de 28, 56, 112 e 224 km² no sul da Amazônia Brasileira. Para isso analisamos dados espacialmente explícitos sobre desmatamento e chuvas entre 1999 a 2019. Concluimos que a quantidade de chuva anual caiu à metade ao longo dos últimos 20 anos em regiões onde a agropecuária ocupou até 60% de áreas antes florestadas, o que pode causar uma perda econômica estimada em US\$ 1 bilhão por ano na produção de soja e carne. Diante destas ameaças, a gestão de riscos agroclimáticos torna-se cada vez mais fundamental. No segundo capítulo expandimos nossa investigação para o CE e quantificamos o risco de mudanças climáticas regionais associadas ao desmatamento durante a janela de cultivo da soja e do milho. Demonstramos empiricamente os riscos de atrasos no início da estação chuvosa, menor volume de chuvas e aquecimento são menores em regiões mais conservadas. Somadas às ameaças associadas às mudanças climáticas globais, eleva-se o número de regiões e anos nos quais os sistemas de dupla safra soja-milho são cultivados sob alto risco climático. No terceiro capítulo estimamos as perdas na produção de grãos em decorrência do clima extremo e investigamos os seus determinantes espaciais. A sazonalidade, volume das chuvas e temperatura apresentam tendência de mudança em ambos os biomas, indicando que o clima não está dentro da sua variabilidade normal. As quebras de produtividade da soja e do milho tem ocorrido mais frequentemente e recentemente, fazendo com que o Brasil deixasse de produzir ≈ 23 milhões de toneladas de grãos. As perdas alcançam 9% e 7% da produção brasileira de soja e milho no mesmo período. Ao longo dos 13 anos analisados os produtores da AM perderam mais de US\$ 8.5 bilhões, o equivalente a \approx US\$ 602.4 milhões/ano devido às quebras de safra. No CE as perdas acarretaram um prejuízo de US\$ ≈ 23.8 bilhões ou \approx US\$ 1.7 bilhões/ano. O desmatamento da AM gerou perdas de US\$ 388.2 milhões (\approx US\$ 27.7 milhões por ano), ao passo em que o desmatamento do CE gerou perdas de US\$ 925.5 milhões (\approx US\$ 66.1 milhões/ano). Estes resultados podem orientar ações focadas em garantir a produção brasileira de grãos em um clima em mudança.

Palavras-chave: Mudanças no uso do solo, Soja, Milho, Pastagem, Clima, Agronegócio Brasileiro.

ABSTRACT

Brazilian agricultural production is expected to continue to increase in response to the growing global demand for food and biofuels. However, agriculture is one of the sectors most susceptible to climatic variations. In this context, the devastation of the Amazon (AM) and Cerrado (CE) biomes raises concern because it contributes to the emission of greenhouse gases that intensify global climate change and synergistically interfere with the regional climate. Starting from this problem, this thesis investigates how regional climate changes (especially those associated with deforestation) can affect the productivity of soybeans, corn and pastures in these regions. In the first chapter we evaluated the loss of native vegetation and the reduction of precipitation in pixels of 28, 56, 112 and 224 km² in the south of the Amazon region. The annual amount of rainfall has halved over the last 20 years in regions where agriculture occupied up to 60% of previously forested areas, which can cause a loss economic growth estimated at US\$ 1 billion per year in the production of soy and meat in the region. Faced with these threats, agroclimatic risk management becomes increasingly fundamental. In this sense, in the second chapter we expand our investigation to the CE Biome and quantify the risk of regional climate change associated with deforestation during the soy and corn growing window. The risks of delays in the beginning of the rainy season, lower rainfall and warming are greater in more deforested regions. Added to the threats associated with global climate change, the number of regions and years in which dual-crop systems are cultivated at low risk is increasing. In the third chapter we estimate the losses in grain production recorded as a result of extreme weather and investigate their spatial determinants. Rainfall and temperature patterns show a tendency to change in both biomes, indicating that the climate is not within its normal variability. The drops in soybean and corn productivity have occurred more frequently and recently, causing Brazil to stop producing ≈23 million tons of grains and reflecting on the income of producers and the national economy. Losses reach 9% and 7% of Brazilian soy and corn production in the same period. Over the 13 years analyzed, AM producers lost more than US\$ 8.5 billion, equivalent to ≈US\$ 602.4 million/year due to crop failures. In the EC, losses resulted in a loss of US\$ ≈23.8 billion or ≈US\$ 1.7 billion/year. AM Deforestation generated losses of US\$ 388.2 million (≈US\$ 27.7 million per year), while deforestation in the CE generated losses of US\$ 925.5 million (≈US\$ 66.1 million/year). These results can guide actions focused on guaranteeing Brazilian grain production in a changing climate.

Keywords: Land use change, Soybean, Corn, Pasture, Climate, Brazil's agribusiness.

LISTA DE ILUSTRAÇÕES

- Figura 1.1:** Diagrama de Sankey das transições de uso e cobertura da terra e área cultivada irrigada para os Biomas (a) Amazônia e (b) Cerrado entre 1985 e 2021. Os dados utilizados são provenientes da coleção 7.1 do MapBiomas (plataforma.brasil.mapbiomas.org).....23
- Figura 2.1:** Fluxos de energia, massa e momento entre a superfície e a atmosfera regulados pelo uso e cobertura do solo. Figura adaptada de LAWRENCE E VANDECAR, 2014.....29
- Figura 3.1:** Estrutura da tese e produtos associados.....36
- Figure 4.1:** Land cover in the Southern Brazilian Amazon as of 2019. Southern Brazilian Amazon encompasses 1.9 million km² of the Amazon biome. Deforested area by 2019 according to Program to Calculate Deforestation in the Amazon (PRODES).....40
- Figure 4.2:** Mean annual rainfall anomalies per forest loss percent within 28, 56, 112 and 224 km grid cells. Two piecewise linear segments from MARS algorithm: a) $D < 57.5\%$ (blue line) and $D \geq 57.5\%$ (red line) for 28 km grid cells, b) $D < 47.5\%$ (blue line) and $D \geq 47.5\%$ (red line) for 56 km grid cells, c) $D < 27.5\%$ (blue line) and $D \geq 27.5\%$ (red line) for 112 km grid cells, d) best fit linear model (dashed red line) for 224 km grid cells. Error bar represents the standard error of the mean rainfall anomaly for each forest loss interval. $P'_{i,j,t}$ are the residual annual rainfall anomalies (in mm/year), where the subscripts i and j represent space dimensions and the subscript t represent time dimension. D represents the progressive forest loss fraction (in percentage).....43
- Figure 4.3:** Percentage of different grid-cell sizes crossing the critical threshold. Percentage of different grid-cell sizes crossing the critical threshold of forest loss in southern Brazilian Amazon over time under the two environmental governance scenarios: Weak scenario (WEG), and Strong scenario (SEG) within 28 km, 56 km and 112 km grid cells.....47
- Figure 4.4:** a-c) Percentage of forest loss, d-f) 28x28 km grid cells reaching the critical threshold, g-i) land use/cover and j-l) rainfall reduction. Percentage of forest loss: a) by 2019, b) simulated for 2050 for SEG and c) WEG. 28x28 km grid cells reaching the critical forest loss threshold: d) by 2019, e) simulated by 2050 for SEG, f) and WEG scenario. Land use/cover: g) by 2019, h) simulated by 2050 for SEG, i) and WEG. Rainfall reduction: j) by 2019, simulated by 2050 for k) SEG and l) WEG.....48
- Supplementary Figure 4.1:** Mean observed annual rainfall in southern Brazilian Amazon. Beige to blue gradient colour indicates the total annual rainfall (mm year⁻¹) from the Tropical Rainfall Measuring Mission between 1999 and 2019.....52
- Supplementary Figure 4.2:** Regression models fitted to TRMM rainfall data along transect from NW to SE across Southern Brazilian Amazon. a Linear model. b Exponential model, c Second-degree polynomial model. d Third-degree polynomial model. e Potential model and f Logarithmic model. All regressions are statistically significant with $p < 0.005$53
- Supplementary Figure 4.3:** Mean annual rainfall estimates for the southern Brazilian Amazon. Beige to blue gradient color indicates the total annual rainfall (mm year⁻¹) calculated by using a second-degree polynomial model. Note that the map clearly shows the signal of the South Atlantic Convergence Zone.....55

Supplementary Figure 4.4: 3-step procedure to calculate the anomalies. Diagram with method steps to calculate the annual rainfall anomaly for each grid cell. i, j, t are the subscripts representing space (i, j) and time (t) dimensions, $P_{i,j,t}$ are the annual rainfall values in mm, $\hat{P}_{i,j}$ are the estimated values of rainfall due to geographical location and elevation; $P^*_{i,j,t}$ is the difference between observed annual rainfall values and the estimated ones due to geographical location and elevation; \bar{P}_t are the annual averages of rainfall calculated throughout the study region; $P'_{i,j,t}$ are the residual annual rainfall anomalies; φ, λ, ζ are the subscripts representing latitude, longitude (in degrees), and elevation (in meters).....	58
Supplementary Figure 4.5: Residues between raw values of observed annual rainfall and the estimated values due to geographical location and elevation. Brown to blue gradient color indicates residues between raw values of observed annual rainfall from the Tropical Rainfall Measuring Mission data and the estimated values after equation (S4.1)	60
Supplementary Figure 4.6: Mean annual rainfall anomalies and the best-fit linear regression with ENSO. Mean annual rainfall anomalies between 1999 and 2019 and the best-fit linear regression (red dashed line) with El Nino Southern Oscillation (ENSO) indexes in the Niño 3.4 region.....	61
Supplementary Figure 4.7: Standard deviation of annual rainfall. Brown to blue gradient color indicates standard deviation of annual rainfall within each 28x28-km grid cell in the period of 1999 to 2019.....	69
Supplementary Figure 4.8: Estimated rainfall reduction by 2019 due to forest loss in grid cells that have crossed the critical threshold of forest loss.....	70
Supplementary Figure 4.9: Simulated agricultural land use by 2050. Simulated agricultural land use by 2050 for a SEG, b and WEG. Deforested area (yellow) by 2019 according to Program to Calculate Deforestation in the Amazon (PRODES).....	70
Supplementary Figure 4.10: Spatial association between forest loss and estimated anomalies for 2019. Spatial variability in anomalies and the Cramer's V (CRAMÉR, 1946) and the Spearman Rank Order Correlation coefficient to measure the spatial association between forest loss and estimated anomalies for c and d cells that have reached the critical threshold of forest loss and a and b cells that have not crossed this limit. Brown to blue gradient color indicates precipitation anomalies (mm) for 2019. Red to pink gradient color indicates forest loss (%) within 28 km grid cells. Each point represents the location of a State Capital.....	71
Supplementary Figure 4.11: Significant effect of Maximum cumulative water deficit on deforestation. One degree grid cells with a significant ($\alpha = 0.05$) temporal effect of the Maximum Climatological Water Deficit on deforestation (MCWD; % yr ⁻¹ mm ⁻¹). Colours indicate change in deforestation for each mm reduction in MCWD as a percentage of the average annual local forest suppression. Note that cells with statically significant effect concentrate in the highly humid forests of Northwestern Amazon.....	72
Supplementary Figure 4.12: Difference of mean annual rainfalls between two periods: 1999-2009 and 2010-2019.....	73
Supplementary Figure 4.13: Length of the dry season in Southern Amazon between 1980 and 2010 obtained from National Oceanic and Atmospheric Administration/US (NOAA) Climate	

Diagnostics Center (CDC) daily precipitation gridded data product, version SA24 data. Years are classified into Long dry season (LDS) and short dry season (SDS) using a 0.75σ threshold. Supplementary Figure 4.13 was created using data from AGUDELO *et al.*, 2019.....74

Figura 5.1: Resultados dos testes de Granger entre desmatamento, clima e produtividade agrícola.....86

Figura 5.2: Curvas de probabilidade de ocorrência dos resíduos de início da estação chuvosa para diferentes intervalos de desmatamento na (a) Amazônia e (b) Cerrado.....90

Figura 5.3: Curvas de probabilidade de ocorrência dos resíduos do volume de chuvas para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) Segunda safra na Amazônia e (d) Segunda safra no Cerrado.....91

Figura 5.4: Curvas de probabilidade de ocorrência dos resíduos de Temperatura máxima para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) segunda safra na Amazônia e (d) segunda safra no Cerrado.92

Figura 5.5: Curvas de probabilidade de ocorrência dos resíduos de Temperatura mínima para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) Segunda safra na Amazônia e (d) Segunda safra no Cerrado.93

Figura 6.1: Modelo espacial autorregressivo usado para a identificação dos determinantes espaciais que afetam os resíduos de produtividade da soja e do milho nos Biomas Amazônia e Cerrado.....107

Figura 6.2: Médias das datas de início da estação chuvosa nos Biomas (a) Amazônia e (b) Cerrado entre 1980 a 2020. A tendência de atraso no estabelecimento da estação chuvosa é estatisticamente significativa na Amazônia e Cerrado (Teste de mann-kendall; $p < 0.05$).....109

Figura 6.3: Tendências climáticas entre 1980 e 2020. Média do volume de chuvas nos Biomas (a) Amazônia e (b) Cerrado. Média da Temperatura máxima na (a) Amazônia e (b) Cerrado. Média da temperatura mínima na (e) Amazônia e (f) Cerrado. Todas as tendências de redução no volume de chuvas e aquecimento são estatisticamente significativas segundo o teste de mann-kendall ($p < 0.05$).....111

Figura 6.4: Expansão da área agrícola destinada ao sistema DC soja-milho entre 2006 e 2019 nos Biomas Amazônia e Cerrado. Destaca-se a ampla expansão principalmente no norte do estado do MT e no MATOPIBA.....113

Figura 6.5: Aumento da produção de soja e milho através da intensificação e extensificação na (a) Amazônia e (b) Cerrado.....115

Figura 6.6: Média dos resíduos de produtividade (%) entre 2006 e 2019 nos Biomas Amazônia e Cerrado para (a) Primeira safra (soja) e (b) Segunda safra (milho).....117

Figura 6.7: Funções de distribuição dos resíduos de produtividade para a (a) Primeira Safra Amazônia; (b) Primeira Safra Cerrado; (c) Segunda Safra Amazônia e (d) Segunda safra Cerrado.....118

Figura 6.8: Média dos resíduos de produtividade entre 2006 e 2019 nos Biomas Amazônia e Cerrado para (a) Primeira safra (soja) e (b) Segunda safra (milho).....	123
Figura 6.9: Média das perdas e ganhos econômicos (U\$\$) entre 2006 e 2019 nos Biomas Amazônia e Cerrado para (a) Primeira safra (soja) e (b) Segunda safra (milho).....	124
Figura Suplementar 6.1: Preços da soja e do milho praticados no mercado internacional entre 2003 e 2019.....	128
Figura Suplementar 6.2: Definição dos períodos de cultivo (Primeira e segunda safras) de acordo com o início da estação chuvosa em cada pixel de 28km x 28km.....	129
Figura Suplementar 6.3: Precipitações médias observadas durante a (a) primeira safra e (b) segunda safra entre 1999 a 2019. Precipitações médias modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.....	131
Figura Suplementar 6.4: Temperaturas máximas médias observadas na (a) primeira safra e (b) segunda safra entre 1999 a 2019. Temperaturas máximas modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.....	131
Figura Suplementar 6.5: Temperaturas mínimas médias observadas na (a) primeira safra e (b) segunda safra entre 1999 a 2019. Temperaturas mínimas modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.....	132
Figura Suplementar 6.6: Rentabilidade da produção de soja e milho na Amazônia e Cerrado calculada a partir do percentual de remuneração do custo de produção da atividade.....	134

LISTA DE TABELAS

Supplementary Table 4.1: Regression models fitted to TRMM rainfall data in Southern Brazilian Amazon.....	55
Supplementary Table 4.2: Residues from the second-degree polynomial model.....	56
Supplementary Table 4.3: Coefficients of the second-degree polynomial model.....	56
Supplementary Table 4.4: Spearman Rank-Order correlation coefficients between rainfall values predicted for the entire time-period of study and those predicted using equations derived for three specific time-periods.....	57
Supplementary Table 4.5: Mean annual anomalies for study region between 1999 and 2019.....	62
Supplementary Table 4.6: Cell grid groups divided by forest loss fraction for the periods 1980–1996 and 1997–2012.....	63
Supplementary Table 4.7: Two-Sample t-test with unequal sample sizes and unequal variance of means of annual rainfall anomalies ($P_{i,j,t}$) for cell groups 1 and 2 for the 1999–2009 and 2010–2019 periods.....	64
Supplementary Table 4.8: Two-Sample t test with equal sample sizes and unequal variance of annual rainfall means for the 1999–2009 and 2010–2019 periods.....	73
Tabela 5.1: Resultados dos testes de Granger entre o desmatamento e a variabilidade climática na Amazônia para a primeira e segunda safras entre 1999 e 2019.....	87
Tabela 5.2: Resultados dos testes de Granger entre o desmatamento e a variabilidade climática do Cerrado para a primeira e segunda safras entre 1999 e 2019.....	87
Tabela 5.3: Resultados dos testes de Granger entre a variabilidade climática e a produtividade da soja e do milho segunda safra produzidos na Amazônia entre 1999 e 2019.....	88
Tabela 5.4: Resultados dos testes de Granger entre a variabilidade climática e a produtividade da soja e do milho segunda safra produzidos no Cerrado entre 1999 e 2019.....	89
Tabela suplementar 6.1: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Amazônia incluindo as variáveis associadas ao desmatamento.....	134
Tabela Suplementar 6.2: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Amazônia retirando as variáveis associadas ao desmatamento.....	135
Tabela Suplementar 6.3: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Cerrado incluindo as variáveis associadas ao desmatamento.....	135
Tabela Suplementar 6.4: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Cerrado retirando as variáveis associadas ao desmatamento.....	136

Tabela Suplementar 6.5: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Amazônia incluindo as variáveis associadas ao desmatamento.....	136
Tabela Suplementar 6.6: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Amazônia retirando as variáveis associadas ao desmatamento.....	137
Tabela Suplementar 6.7: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Cerrado incluindo as variáveis associadas ao desmatamento.....	137
Tabela Suplementar 6.8: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Cerrado retirando as variáveis associadas ao desmatamento.....	138
Tabela suplementar 6.9: Produção de soja e milho (em U\$\$) entre 2003 e 2019.....	138
Tabela suplementar 6.10: Produção no Cerrado e na Amazônia em relação à produção brasileira de soja e milho entre 2003 e 2016.....	139
Tabela suplementar 6.11: Perdas totais na produção de soja e milho no Cerrado e na Amazônia.....	139
Tabela suplementar 6.12: Perdas totais no Cerrado e da Amazônia em relação à produção brasileira de soja e milho entre 2003 e 2019.....	139
Tabela suplementar 6.13: Síntese dos impactos econômicos associados às quebras de produtividade e ao efeito direto e indireto do desmatamento entre 2003 e 2019.....	140

LISTA DE ABREVIATURAS E SIGLAS

AA	Anomalous Accumulation
AIC	Critério De Informação de Akaike
AM	Amazônia
AMACRO	Amazonas, Acre, Rondonia
CCM3	Community Climate Model Version 3
CE	Cerrado
CO2	Dióxido de Carbono
CONAB	Companhia Nacional de Abastecimento
DC	Sistema Dupla Safra Soja-Milho
EAA	Equivalent Annual Annuity
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ENSO	El Niño Southern Oscillation
FAO	Organização das Nações Unidas para a Alimentação e a Agricultura
GDHY	Global Dataset of Historical Yield
GEE	Gases de Efeito Estufa
GHG	Greenhouse Gas
IBGE	Instituto Brasileiro de Geografia E Estatística
IBGE	Brazilian Statistics Institute
INLAND	Integrated Model of Land Surface Processes
IPCC	Intergovernmental Panel on Climate Change
LUCC	Land Use and Cover Change
MARS	Multivariate Adaptive Regression Spline
MATOPIBA	Maranhão, Tocantins, Piauí e Bahia

MC	Monte Carlo
MT	Mato Grosso
NPV	Net Present Values
ODS	Objetivos de Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
ODP	Oscilação Decadal do Pacífico
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia por Satélites
RF	Random Forest
SAR	Spatial Lag Model
TRMM	Tropical Rainfall Measuring Mission
ZCIT	Zona de Convergência Intertropical

SUMÁRIO

1 APRESENTAÇÃO	19
1.1 Contextualização da problemática abordada	19
1.2 Contextualização teórica	22
1.2.1 Quebras de safra.....	22
1.2.2 Mudanças climáticas globais ligadas ao acúmulo de GEE na atmosfera.....	23
1.2.3 Mudanças climáticas locais e regionais induzidas pelo desmatamento	25
2 OBJETIVOS	30
2.1 Objetivo geral	30
2.2 Objetivos específicos	30
3 ESCOPO DA TESE	33
4 CAPÍTULO 1	35
4.1 Introduction	37
4.2 Results and Discussion	39
4.2.1 Relationship between deforestation and rainfall at different geographical scales	39
4.2.2 Additional evidence for forest loss causation of rainfall reduction.....	42
4.2.3 Future critical forest loss thresholds and agricultural economic losses	43
4.3 Methods	46
4.4 Supplementary Methods	49
4.4.1 Modelling the spatial variability of annual rainfall:.....	49
4.4.2 Detrending procedure.....	54
4.4.3 Verification of the detrending method	57
4.4.4 Separating the effects of forest loss from the mean trend in rainfall	60
4.4.5 Environmental governance scenarios.....	61
4.4.6 Effects of deforestation on agricultural production and economic	62
4.4.7 How a reference yield is modified as the local climate changes due to incremental forest loss .	62
4.5 Supplementary results and discussion	65
4.5.1 How relevant these rainfall reductions are in magnitude	65
4.5.2 Evidence for forest loss causation of rainfall reduction.....	68
4.5.3 Spatially-explicit signal of the reduction of rainfall in the region	70
4.6 supplementary figures	71

5	CAPÍTULO 2	72
5.1	introdução	74
5.2	dados e métodos	75
5.2.1	Região de estudo	75
5.2.2	Dados	76
5.2.3	Início da estação chuvosa	77
5.2.4	Períodos de cultivo	78
5.2.5	Resíduos de precipitação, temperatura e início da estação chuvosa	78
5.2.6	Resíduos de produtividade	79
5.2.7	Testes de Granger	80
5.2.8	Riscos agroclimáticos associados ao desmatamento	81
5.3	Resultados e discussão	82
5.3.1	Testes de Granger	82
5.3.2	Riscos agroclimáticos associados ao desmatamento	86
5.3.3	A conservação ambiental e a mitigação dos riscos agroclimáticos	90
5.4	Conclusões	92
6	CAPÍTULO 3:	93
6.1	Introdução	95
6.2	Dados e métodos	97
6.2.1	Região	97
6.2.2	Dados	98
6.2.3	Início da estação chuvosa	100
6.2.4	Definição dos períodos de cultivo	100
6.2.5	Resíduos climáticos devido ao desmatamento	101
6.2.6	Quebras e ganhos de safra (resíduos de produtividade)	102
6.2.7	Modelagem espacial da área plantada	102
6.2.8	Determinantes das quebras e ganhos de produtividade	103
6.2.9	Impactos econômicos	106
6.3	Resultados e discussão	106
6.3.1	Ameaças climáticas	106
6.3.2	Evolução da área plantada e da produtividade da soja e do milho	110
6.3.3	Aumento das quebras de safra	114

6.3.4	Determinantes espaciais das variações de produtividade.....	117
6.3.5	Perdas agrícolas potenciais e impactos associados	120
6.3.6	Impactos econômicos potenciais e na receita atingida com as exportações.....	121
6.3.7	Perdas agrícolas potenciais e impactos associados ao desmatamento	122
6.4	Conclusão	123
6.5	Material suplementar	125
6.5.1	Produtividade agrícola	125
6.5.2	Cotações da soja e milho.....	126
6.5.3	Definição dos períodos de cultivo.....	126
6.5.4	Cálculo das anomalias climáticas em cada período de cultivo	128
6.5.5	Rentabilidade econômica	131
7	CAPÍTULO FINAL	139
7.1	Medidas de adaptação para o milho e soja produzidos no Cerrado e na Amazônia	139
7.1.1	Ajustes de datas de plantio e cultivares.....	140
7.1.2	Irrigação	141
7.1.3	Uso de fertilizantes.....	141
7.1.4	Transformação em grande escala da agricultura	142
8	CONSIDERAÇÕES FINAIS	143
9	REFERÊNCIAS	145
8	GLOSSÁRIO	155

1 APRESENTAÇÃO

1.1 Contextualização da problemática abordada

Nas décadas de 60 e 70 o Brasil vivia um período de intenso crescimento econômico. O País passava por um momento de forte industrialização, com cidades em expansão, aumento da população e do poder aquisitivo. Entretanto, a modernização não se materializava no campo. Muito pouco se sabia sobre fertilizantes e novas variedades de altos rendimentos, além disso, menos de 2% das propriedades rurais adotava algum tipo de mecanização (CORONEL, 2010). Diante deste quadro, a produção agrícola não supria a demanda interna de alimentos e o abastecimento mantinha-se dependente das importações. Naquela época a soja era uma curiosidade, sem expressão para o mercado brasileiro e para o comércio internacional (HIRAKURI; LAZZAROTTO, 2011).

O cenário começou a mudar no início da década de 80. Através de massivos investimentos em pesquisa, inovação e extensão agrícola aliados à instituição do Sistema Nacional de Crédito Rural (CHADDAD, 2016), a produção agrícola (majoritariamente grãos) cresceu mais de cinco vezes (IBGE, 2022). Os investimentos em tecnologia fizeram com que a soja se tornasse mais independente do fotoperíodo, podendo ser plantada mais cedo, para que, depois da colheita, fosse possível produzir outras culturas numa mesma estação chuvosa. Não obstante, o milho produzido como segunda safra depois da soja precoce (sistema de cultivo duplo soja-milho; Sistema DC) representa mais da metade da produção nacional do grão. A partir da década de 1990, demandas crescentes e políticas macroeconômicas de estabilização, como controle da inflação e taxas de câmbio mais realistas, impulsionaram ainda mais o crescimento do setor agrícola, que passou a ser o principal responsável pelo superávit da balança comercial brasileira (FRIES; CORONEL, 2014; MARTINELLI *et al.*, 2011). Em três décadas o Brasil deixou de ser um importador para se tornar um grande exportador ao lado da Ucrânia, União Europeia e Estados Unidos. Hoje o País abastece $\approx 50\%$ e $\approx 10\%$ das demandas globais de soja e milho, respectivamente (TRASE, 2021).

Durante o período de intenso crescimento, a maioria das terras férteis no Sul e Sudeste do País já haviam sido ocupadas. Consequentemente, produtores migraram para outras regiões em busca de terras e oportunidades. Impulsionados pelas variedades adaptadas geneticamente e sistemas modernos de correção do solo, em menos de duas décadas os plantios chegaram ao Nordeste e ao Norte do país. Este avanço acontece sobretudo em direção às vastas extensões

dos biomas Amazônia (AM) e Cerrado (CE), que, ainda hoje vem sendo rapidamente convertidos em grandes cultivos agrícolas (SCHLESINGER; NORONHA, 2006; Figura 1.1). Não obstante, a velocidade com que a fronteira agrícola avança na AM (Figura 1.1a) e no CE (Figura 1.1b) está acima da média nacional (FREITAS JR, 2013). Muitos produtores se instalaram no Mato Grosso do Sul, no Triângulo Mineiro, no Sul de Goiás e na região em torno de Sorriso e Lucas do Rio Verde, já em Mato Grosso. Essas regiões se consolidaram como importantes produtoras de grãos e impulsionaram ainda mais o crescimento do setor.

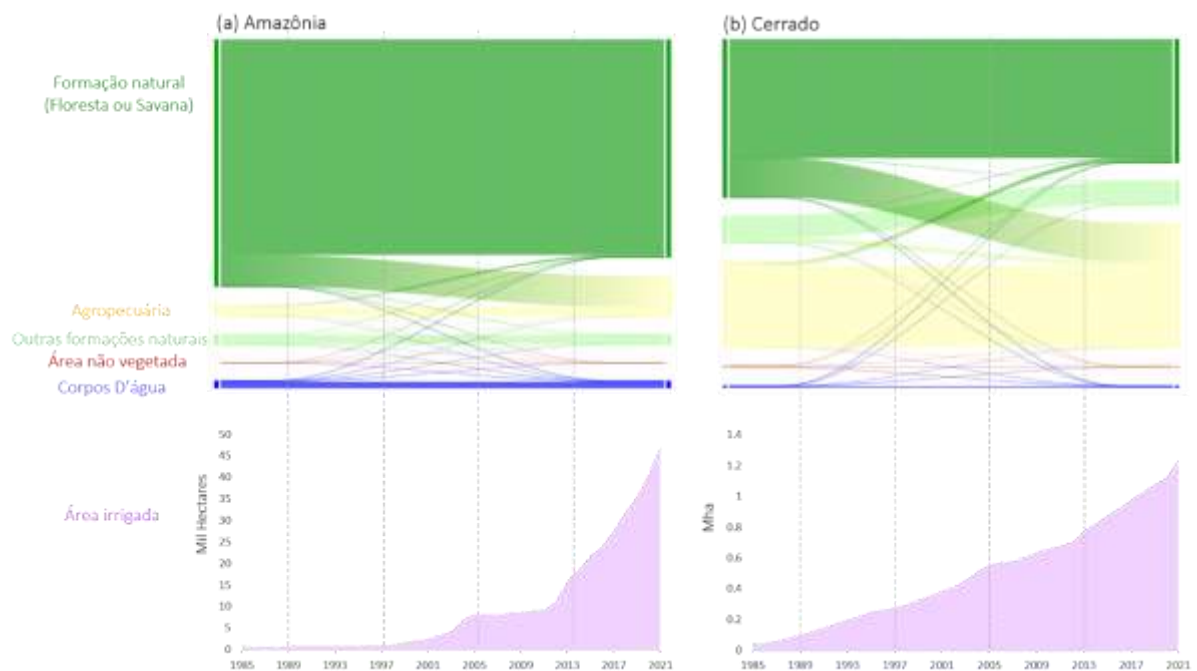


Figura 1.1: Diagrama de Sankey das transições de uso e cobertura da terra e área cultivada irrigada para os Biomas (a) Amazônia e (b) Cerrado entre 1985 e 2021. Os dados utilizados são provenientes da coleção 7.1 do MapBiomas (plataforma.brasil.mapbiomas.org).

Mesmo diante dos marcantes avanços tecnológicos, a adoção de sistemas de irrigação ainda é pouco expressiva. Mais de 90% dos agricultores na AM Brasileira e CE dependem das chuvas para produzir (ANA; IBGE, 2020; Figura 1.1), ou seja, estão susceptíveis aos eventos extremos e à variabilidade climática. Não obstante, nos últimos anos eventos climáticos severos têm prejudicado o agronegócio brasileiro ao causar expressivas quebras de safra (Definidas na seção 1.2.1). A chuvas irregulares e em uma quantidade 50% menor que a média causaram uma perda de 7,3 milhões de toneladas de grãos, principalmente soja e milho na safra 2020/21. O impacto da seca na safra 2021/2022 na soja foi calculado em R\$ 72 bilhões, pressionando o Produto Interno Bruto (PIB) da Agropecuária no segundo trimestre de 2022, que apresentou queda de 12,0% frente ao primeiro trimestre (IBGE, 2022). Diante destas ameaças cada vez

mais claras, o Painel Intergovernamental sobre Mudanças Climáticas da ONU tem destacado as mudanças climáticas globais (ligadas ao acúmulo de Gases do efeito estufa na atmosfera – GEE- seção 1.2.2) e regionais (induzidas pelo desmatamento - seção 1.2.3) na AM e Centro-Oeste brasileiros que ameaçam a agricultura e afetam significativamente a sustentabilidade econômico-financeira dos negócios agrícolas (PÖRTNER; ROBERTS, M.; TIGNOR, 2022). Neste ponto é importante ressaltar a interligação entre a expansão do próprio setor agrícola e as mudanças climáticas locais, regionais e globais já que o agronegócio é o principal responsável pelo desmatamento no Brasil (AZEVEDO *et al.*, 2022). Cria-se, portanto, uma situação paradoxal: O agronegócio se expande para aumentar a produção, entretanto, ao desmatar para produzir, contribui para mudanças climáticas que afetam a sua própria atividade.

Isto se deve a dois pontos principais: (i) As atividades de uso do solo (principalmente a conversão de áreas naturais em cultivos agrícolas) compõem a maior parte das emissões de GEE brasileiras, retroalimentando positivamente a crise climática global (GATTI *et al.*, 2021). Prova disso, é o aumento em 9,5% das emissões brasileiras em 2020, enquanto no mundo inteiro elas despencaram em quase 7% devido à pandemia de COVID-19. O desmatamento na AM foi principal responsável pela elevação das emissões no Brasil (POTENZA *et al.*, 2021); (ii) A conversão das áreas naturais em ecossistemas agrícolas intensifica mudanças nas interações biosfera-atmosfera que promovem reflexos diretos na ciclagem de umidade e no balanço de energia à superfície (COSTA *et al.*, 2007) e conseqüentemente estão ligados à menores volumes de chuvas (LEITE-FILHO *et al.*, 2021), atrasos no início do período chuvoso (LEITE-FILHO; COSTA; RONG, 2019b, LEITE-FILHO 2019a) e aumento nas temperaturas (GATTI *et al.*, 2021). Há de se ressaltar que o clima local e regional pode responder tanto ou mais fortemente ao desmatamento do que ao aquecimento global (PONGRATZ *et al.*, 2012; DE NOBLET-DUCOUDRE *et al.*, 2012). Não obstante, o desmatamento já afeta o clima nas principais regiões produtoras de grãos na AM e CE. A perda florestal já fez com que o estado do Mato Grosso, maior produtor e exportador de soja e milho do país, perdesse quase um mês de chuva, enquanto o estado de Rondônia perdeu quase duas semanas (LEITE-FILHO *et al.*, 2021). Para cada ponto percentual de aumento do desmatamento na AM, a temporada de chuvas diminui entre 0,12 e 0,17 dia (LEITE-FILHO; COSTA; FU, 2019a). No CE a conversão de áreas nativas para pastagens e agricultura já tornou o clima na região quase 1°C mais quente e 10% mais seco (RATTIS *et al.*, 2021).

As projeções futuras também são preocupantes. Em um cenário com aumento do desmatamento da AM e do CE, a redução das chuvas e as perdas de produtividade aumentam drasticamente (PIRES *et al.*, 2016). As perdas devem alcançar pelo menos 4,5 bilhões de dólares por ano em 2050, em uma estimativa conservadora. Se o desmatamento continuar descontrolado, o prejuízo pode chegar a US\$ 9 bilhões por ano (FLACH *et al.*, 2021). Como consequência, além de impactar a produção agrícola de uma região/país, as quebras de safra afetam diretamente a rentabilidade da atividade, pois impacta a receita do produtor. Entretanto, quem paga essa conta, além dos produtores, é a sociedade brasileira e o mundo. As reduções de safra têm impactos sobre políticas de definição de preços, de logística de transportes e de planejamento de estoques públicos, ou seja, afetam diretamente a segurança alimentar (ASSAD *et al.*, 2007).

1.2 Contextualização teórica

1.2.1 Quebras de safra

Não há uma definição explícita na literatura científica de *quebra de safra*, entretanto, esta pode ser entendida como uma redução significativa do resultado de uma colheita, usualmente medida em termos de produção total ou produtividade, em relação ao volume projetado para a safra (COSTA; ABRAHÃO, 2017). LESK; ROWHANI; RAMANKUTTY, 2016, partindo do princípio de que quebras de produção causadas por problemas climáticos têm sido reportadas em diversas regiões do globo, buscaram estimar, de forma pioneira, as perdas na produção global de cereais. Para isso utilizaram-se bases de dados divulgados de desastres climáticos ocorridos entre 1964 e 2007. A metodologia adotada foi a análise de época sobreposta, com o objetivo de isolar e mensurar os sinais de efeito resposta dos eventos climáticos extremos utilizando base de dados de produção nacional de 177 países. Os resultados mostraram que as secas e o calor excessivo reduziram significativamente a produção de cereais (9% a 10%). Importante destacar que foi constatado que as perdas de produção devido às secas foram associadas à uma redução tanto na área colhida, quanto na produção, enquanto o calor extremo diminuiu principalmente a produção de cereais.

HIRAKURI; LAZZAROTTO, 2014 observaram que a área cultivada no mundo aumentou 49,8%, enquanto a produtividade cresceu 61,5% no período compreendido entre as safras de 2000/2001 e 2013/2014. A maior produtividade alcançada em menor área cultivada foi possível dado ao avanço tecnológico em nível mundial e que esse aumento de produtividade

poderia ter sido ainda maior não fossem os problemas agroclimáticos geradores de quebras de safras nos principais países produtores da oleaginosa (Brasil, Estados Unidos da América e Argentina), com períodos críticos em termos de produção global como as safras de 2008/2009 e 2011/2012. Em estudo sobre mudanças no regime de chuvas e quebras de safra no Brasil entre 1990 e 2014, COSTA; ABRAHÃO, 2017 apontam que as maiores quebras para a soja vêm ocorrendo no sul do Brasil e na região do MATOPIBA (Maranhão, Tocantins, Piauí e Bahia). Para o milho, as quebras identificadas foram mais dispersas, com maior incidência no Nordeste. No Brasil, grandes quebras de safras estão, em geral, associadas aos efeitos climáticos adversos dos fenômenos *El Nino* e *La Nina* (BERLATO; FONTANA, 2001).

1.2.2 Mudanças climáticas globais ligadas ao acúmulo de GEE na atmosfera

Mudanças climáticas são globais variações no clima que podem ser identificadas (usando testes estatísticos) por mudanças na média e/ou na variabilidade de suas propriedades e que persistem por um longo período, tipicamente décadas ou mais. Ela refere-se a qualquer mudança do clima ou qualquer que seja sua decorrência, tanto por variações naturais ou pelas atividades humanas (MATTHEWS *et al.*, 2018). Isto porque, as mudanças climáticas sempre existiram devido a diversos fatores naturais, tais como erupções vulcânicas, oscilações na atividade solar ou mesmo devido à variabilidade interna do clima. Dois eventos são ilustrativos dessas variações naturais. A Pequena idade do Gelo (GROVE, 1988), entre os anos 1300 e a década de 1850, na qual a Europa e América do Norte sofreram com um período marcado por frio intenso e consequente uma expansão das geleiras. Em outro momento (950-1250 d.C.), 40% da superfície da Terra registrou aumentos significativos de temperatura, principalmente na Europa, o Período Quente Medieval (GOOSSE *et al.*, 2006).

Nas últimas décadas tem se observado mudanças climáticas globais com características bem distintas das vistas nos períodos anteriores. Em primeiro lugar, enquanto as mudanças climáticas naturais são relativamente lentas, as mudanças climáticas observadas desde 1880 têm ocorrido de forma abrupta, com a elevação da temperatura média em 1,1°C, sendo que aproximadamente metade desse aumento ocorreu nos últimos 20 anos (TEAM, 2022; LENNSEN *et al.*, 2019). A velocidade das mudanças é preocupante pois ela reduz a possibilidade de adaptação dos seres vivos e tecnologias às novas condições. Em segundo lugar, existe um claro consenso na ciência que essas mudanças ocorreram em consequência do aumento dos gases de efeito estufa. Esses gases são elementos químicos como o dióxido de

carbono (CO₂), metano (CH₄) entre outros que estão presentes naturalmente na atmosfera, representando menos de 0.1% da sua composição. Porém, ao contrário do nitrogênio e oxigênio, que representam respectivamente 78% e 21% da composição do ar que respiramos, os gases de efeito estufa retêm o calor gerando um efeito similar ao das estufas usadas na agricultura (HAYNES; LIDE; BRUNO, 2014).

Desde o final do século XIX estudos apontam que uma pequena variação na composição da atmosfera com o aumento da presença de gases de efeito estufa pode gerar um aumento significativo na temperatura média do planeta (ARRHENIUS , 1896). As evidências de uma alteração antrópica do clima se acumulam provenientes de diversas fontes: os anéis dos troncos de árvores, amostras de gelo, sedimentos em lagos e corais, por exemplo, trazem consigo um registro histórico do clima no passado que não nos deixam dúvidas de que as mudanças atuais não possuem precedentes e não são naturais. Portanto, é extremamente provável que mais da metade do aumento observado da temperatura média da superfície global entre 1951 e 2010 tenha sido causado pela influência humana sobre o clima através das emissões de Gases Efeito Estufa (MASSON-DELMOTTE *et al.*, 2021).

Até certos limites de concentração, o aumento do CO₂ faz as plantas serem mais eficientes na produção de matéria orgânica, o chamado efeito de “fertilização de CO₂”. Assim, as plantas precisam de menos água para produzir a mesma quantidade de matéria orgânica por meio da fotossíntese. Entretanto, há muitos outros fatores controlando a eficiência fotossintética e, no conjunto de todos os fatores ambientais, a fertilização de CO₂ em induzir aumento da produtividade não é capaz de compensar o severo impacto negativo na produtividade causado pela sinergia entre as mudanças climáticas locais, regionais e globais na maior parte do país (WANG *et al.*, 2020). Sendo assim, o aumento da temperatura média do planeta em 1,1° C pode parecer pouco, mas essa mudança já trouxe impactos significativos.

Nos últimos 125 mil anos a Terra nunca foi tão quente como é hoje, e há muita confiança de que o aumento da frequência dos extremos climáticos, como secas e inundações ocorridas na segunda metade do século 20, está diretamente ligado ao aquecimento global causado pelo homem (MASSON-DELMOTTE *et al.*, 2021). Existem evidências que as mudanças climáticas já ocorridas entre 1961-2020 reduziram a produtividade da agricultura globalmente, cancelando parcialmente os ganhos de produtividade obtidos com a introdução de novas tecnologias. Essas perdas foram sentidas principalmente no Brasil, que apesar de ter aumentado a produtividade

média em 190% nesse período, teria tido um aumento adicional entre 20-25% na ausência das mudanças climáticas (ORTIZ-BOBEA *et al.*, 2021). Esse resultado corrobora as previsões feitas nos anos 2000 que apontam para o aumento das perdas agrícolas, principalmente no sul do Brasil e na segunda safra do centro-oeste (ORTIZ-BOBEA *et al.*, 2021; ASSAD *et al.*, 2007)

A queima de combustíveis fósseis é o principal causador das mudanças climáticas. Desde a Era Industrial, houve um aumento de 50% da quantidade de dióxido de carbono (CO₂) na atmosfera, o mais abundante entre os GEE (BETTS, 2021). Porém, o desmatamento, uso de fertilizantes e emissões entéricas da criação de animais também são causadores significativos das mudanças climáticas, gerando 24% das emissões totais (SMITH *et al.*, 2014). O Brasil se diferencia dos outros países do mundo pois possui uma matriz energética relativamente limpa e com baixas emissões per capita ligadas à queima de combustíveis fósseis. O Brasil é o país com os maiores índices de desmatamento e o segundo maior rebanho bovino do mundo, fazendo com que a agropecuária e o desmatamento representem 70% das emissões do país em 2020 (MCTI). E apesar do Brasil estar entre os 4 maiores países geradores de GEE, ele representa somente 5% do total emitido no planeta. Os Estados Unidos são responsáveis por 20% do total de emissões. A China aparece em segundo lugar, como responsável por 11% do CO₂ global e a Rússia vem em terceiro com 7% das emissões (EVANS, 2021).

1.2.3 Mudanças climáticas locais e regionais induzidas pelo desmatamento

Aparte das mudanças observadas a nível global, os climas local e regional também estão se alterando em muitas partes do mundo. Essas alterações ocorrem principalmente em resposta a distúrbios na interação entre a atmosfera local/regional e a cobertura da terra. A conversão de ecossistemas naturais (florestas, savanas) em usos antrópicos para expansão urbana e agrícola causa uma série de alterações físicas e químicas que desestabilizam a atmosfera, o que chamamos de mudanças climáticas regionais e locais. Os efeitos do desmatamento (em particular a substituição da vegetação por culturas agrícolas, pastagens ou outros usos antrópicos) dependem dos tipos de uso do solo envolvidos na transição. Aqui nos concentraremos nos efeitos biogeofísicos do desmatamento da AM e CE.

O uso e a cobertura do solo mediam os fluxos de energia, massa e momentum entre a superfície terrestre e a atmosfera (Figura 1.2). A vegetação tropical possui albedo menor do que culturas agrícolas e pastagens. A redução do albedo com o desmatamento faz com que mais radiação seja refletida e diminui o saldo de radiação disponível para os processos superficiais

(COSTA, 2005). A vegetação natural da AM e CE também possui maior evapotranspiração, principalmente devido às suas raízes geralmente mais profundas e área foliar maior, capazes de remover mais umidade do solo e bombeá-las para a atmosfera. Isso afeta a partição do saldo de radiação, fazendo o desmatamento aumentar a fração de fluxo de calor sensível, diminuindo o fluxo de calor latente (BONAN, 2008). A vegetação natural também é mais heterogênea e mais alta, fazendo com que superfícies desmatadas tenham uma menor rugosidade e consequentemente maior velocidade horizontal do vento, diminuindo a geração de turbulência e transferência de momentum para a atmosfera.




Figura 1.2: Fluxos de energia, massa e momento entre a superfície e a atmosfera regulados pelo uso e cobertura do solo. Figura adaptada de LAWRENCE E VANDECAR, 2014.

Em modelos de escala local, o efeito dessas mudanças nos fluxos de superfície causados pelo desmatamento geralmente se traduz em aumento da temperatura e redução do volume de chuvas (ZENG; NEELIN, 1999; YANAGI, 2006). O aumento de temperatura é naturalmente esperado pelo aumento no fluxo de calor sensível, que aquece a atmosfera próxima ao solo. Já

as mudanças na precipitação são mais incertas e, mesmo em modelos muito simples, depende de ciclos complexos de retroalimentação. ZENG; NEELIN, 1999 explicam que o efeito de pequenas reduções na cobertura de árvores em uma região de convecção profunda como as florestas tropicais pode ser na maioria explicada simplesmente pelos efeitos termodinâmicos causados pela redução do albedo. Menos energia na superfície enfraquece tanto a convecção, os movimentos ascendentes necessários para a formação de precipitação, quanto a convergência de umidade. Também leva a menos evapotranspiração, o que também diminui a umidade disponível na camada limite. A evapotranspiração não só é reduzida pela redução no saldo de radiação, mas também pela menor fração deste ser transformada em calor latente e a redução da rugosidade (SENNA; COSTA; PIRES, 2009).

Essas mudanças também se retroalimentam de diferentes maneiras ao nível local. A diminuição da precipitação também leva a menos água disponível para a evapotranspiração, retroalimentando positivamente o sistema. Por outro lado, a redução da convecção também leva a uma menor cobertura de nuvens aumenta a radiação na superfície em um feedback negativo entre o saldo de radiação, a cobertura de nuvens e a precipitação, mitigando o efeito inicial da mudança de albedo (ZHANG; HENDERSON-SELLERS; MCGUFFIE, 1996). Porém, esse mesmo mecanismo aumenta a radiação na superfície e aumenta o aquecimento causado pelo aumento da fração de calor latente. O efeito líquido desses ciclos de retroalimentação tende a ser no sentido de redução da precipitação de forma aproximadamente linear com o aumento do albedo, e aumento na temperatura (ZENG; NEELIN, 1999). Estudos observacionais corroboram o efeito de aquecimento do desmatamento tropical com efeitos até duas vezes mais intensos na temperatura máxima do que na temperatura média (ALKAMA; CESCATTI, 2016; COHN *et al.*, 2019)

Os efeitos locais observados na precipitação dependem de fenômenos em outras escalas. Mesmo uma região pequena com, por exemplo, 50% de área desmatada é uma paisagem heterogênea, com algumas partes completamente florestadas e outras completamente desmatada. Essa heterogeneidade induz fluxos de advecção entre essas diferentes partes, gerando efeitos de mesoescala (D'ALMEIDA *et al.*, 2007). Na fronteira entre floresta e não floresta, o maior aquecimento da região desmatada induz o movimento de ar úmido da floresta para a não floresta, um fenômeno por vezes chamado de brisa do desmatamento (LAWRENCE; VANDECAR, 2014)

Para fragmentos desmatados pequenos (da ordem de alguns quilômetros) rodeados de floresta, o movimento de umidade vindo da floresta, juntamente com a turbulência transportada, leva a um movimento ascendente do ar na região não desmatada. A diferença de rugosidade causa um aumento na velocidade do vento sobre a região desmatada, induzindo um movimento de subsidência a barlavento. Esse efeito combinado ao aquecimento diferencial tende a formar uma célula horizontal no fragmento desmatado (SAAD *et al.*, 2010, KHANNA *et al.*, 2017). Essa célula cria um dipolo de precipitação, com uma região de ascensão do ar e aumento da precipitação a sotavento e subsidência e redução a barlavento. Considerando o fragmento desmatado na totalidade, o efeito líquido desse dipolo é de aumento de precipitação até certo tamanho de fragmento. Esse tamanho pode depender de diversos fatores, inclusive da orientação do fragmento em relação ao vento predominante (SAAD *et al.*, 2010), e provavelmente da distribuição de fragmentos na região circundante (NOBRE *et al.*, 2009). Em fragmentos muito grandes esses efeitos de advecção enfraquecem considerando o fragmento na totalidade, e os efeitos das mudanças nos fluxos de superfície mencionadas voltam a dominar. Ou seja, para fragmentos desmatados muito grandes e/ou uma fragmentação muito forte de uma grande área, o papel da vegetação como recicladora de umidade também passa a ser importante, gerando efeitos tanto localmente quanto em regiões distantes.

A diminuição da evapotranspiração geralmente leva a redução da precipitação local, mas também pode afetar regiões a sotavento para as quais a região desmatada transporta umidade (SPRACKLEN; ARNOLD; TAYLOR, 2012; KEYS *et al.*, 2017). O desmatamento da área circundante afeta a dissipação de calor por convecção por toda a região, e o aquecimento da camada limite atmosférica em áreas próximas se espalha a uma certa distância da área desmatada. COHN *et al.*, 2019 analisaram o efeito na temperatura máxima do desmatamento de regiões próximas de pontos circundados por pelo 1 km de vegetação natural, buscando isolar os efeitos não locais. Eles encontram um efeito aproximadamente linear com o desmatamento de um halo entre 1 e 50 km de distância do ponto considerado. Esse efeito é da ordem de $\sim 0.2^{\circ}\text{C}$ de aumento na temperatura máxima média para cada 10% de desmatamento, tendo magnitude similar aos efeitos do desmatamento local em pixels de ~ 6 km de resolução espacial (ALKAMA; CESCATTI, 2016)

O desmatamento também pode gerar efeitos em sistemas meteorológicos de grande escala, especialmente quando ocorre em grandes extensões. No caso da América do Sul, a presença da floresta tem um efeito importante em facilitar a convecção profunda no continente

no fim da estação seca, impulsionando o fluxo de umidade do oceano para o continente e iniciando a estação chuvosa (WRIGHT *et al.*, 2017). Esse efeito pode explicar em parte o atraso na estação chuvosa com o desmatamento encontrado tanto em modelos quanto observações (COSTA; PIRES, 2009; BUTT; DE OLIVEIRA; COSTA, 2011; LEITE-FILHO *et al.*, 2020; LEITE-FILHO; COSTA; RONG, 2019b) e a sensibilidade maior ao desmatamento da precipitação na estação seca em regiões próximas ao oceano encontrada por SUMILA *et al.*, 2017.

O desmatamento de entre 50% e 100% da região amazônica também pode causar mudanças na circulação de larga escala suficientes para alterar os oceanos, incluindo mover a ZCIT (Zona de Convergência Intertropical, ver resposta da próxima questão) do Atlântico algumas centenas de quilômetros para norte e reduzir o gradiente de temperatura do Pacífico favorecendo eventos de *El Niño* (NOBRE *et al.*, 2009). Esses efeitos, além de outros relacionados a feedbacks do clima na própria vegetação como mudanças na composição atmosférica (PIRES; COSTA, 2013), aumento de queimadas (LOVEJOY ; NOBRE, 2018) e a incapacidade de a evapotranspiração da floresta sustentar a evaporação no continente (BOERS *et al.*, 2017), podem levar a um ponto de inflexão depois do qual o desmatamento adicional teria efeitos ainda mais drásticos e a floresta não seria capaz de se regenerar.

Estudos específicos sobre esse tema colocam esse ponto em pelo menos 40% de desmatamento de toda a AM, tanto considerando a transição de biomas (PIRES; COSTA, 2013) quanto apenas a reciclagem de umidade (BOERS *et al.*, 2017). Porém, há considerável incerteza sobre esse ponto, na maioria devido ao pouco entendimento de processos importantes como a transição de biomas, limitação nutricional e efeitos do fogo (LAWRENCE; VANDECAR, 2014). Os efeitos do desmatamento na precipitação dependem tanto da escala analisada (região em que se agregam os efeitos), da magnitude do desmatamento (fração da região que é desmatada) e da escala dos processos considerados (resolução de modelos de simulação). Os efeitos de mesoescala que podem ter o efeito líquido de aumentar a precipitação sobre a região desmatada tendem a criar células verticais, com alguma subsidência e supressão da precipitação sobre alguma região circundante ou dentro da região desmatada, como observado por SAAD *et al.*, 2010 e KHANNA *et al.*, 2017 em escalas de algumas dezenas de quilômetros. Isso faz com que análises feitas em escalas mais agregadas possam suavizar padrões de escala menor, como os dipolos de precipitação mencionados. Esse efeito da agregação fica bastante claro em uma análise recente da relação entre precipitação anual observada por satélite e desmatamento na

região Sul da AM (LEITE-FILHO *et al.*, 2021). Na escala original dos dados (pixels de ~28 km de lado), fica claro um efeito não linear do desmatamento, com uma tendência de aumento da precipitação até níveis de desmatamento até ~28% e diminuindo para níveis maiores. Ao se repetir a análise com os dados agregados para uma grade de 200 km de lado, tanto os efeitos positivos quanto negativos são atenuados e o ponto de inflexão diminui. Após a agregação para uma grade de 200 km de lado a tendência é de redução praticamente linear com o desmatamento, sendo difícil determinar um ponto de inflexão.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo central desta tese é explorar as interações entre o desmatamento do CE e da AM, as mudanças climáticas regionais (no volume e sazonalidade das chuvas e nos padrões de temperatura máxima e mínima) induzidas pelo desmatamento e a produtividade e produção agrícola de pastagens, soja e milho cultivados nestes Biomas. **Motivação:** O desmatamento gera impactos imediatos nas chuvas e na temperatura, que podem ocorrer localmente, regionalmente e até em outros continentes. Estas mudanças climáticas induzidas pelo desmatamento interagem com o aquecimento global causado pelas emissões de gases de efeito estufa, cada um potencialmente tendo um efeito agravante sobre o outro. Os modelos sugerem que existem pontos de inflexão após os quais os impactos irão acelerar e os riscos para a agricultura, podem se tornar permanentes.

2.2 Objetivos específicos

Os objetivos específicos desta tese e suas respectivas motivações são:

(1) Quantificar a relação entre mudanças na cobertura florestal e mudanças na precipitação local, regional e de larga escala no Sul da Amazônia Brasileira. **Motivação:** O Sul da AM é uma das fronteiras de uso da terra mais dinâmicas do mundo e responde pela maior parte das terras agrícolas e pastagens na AM. Modificações no balanço de energia decorrentes do desmatamento podem alterar padrões de precipitação principalmente quando a conversão de florestas em outros usos da terra ocorre em larga escala. No entanto, as relações entre o desmatamento e a precipitação em diferentes escalas ainda permanecem pouco conhecidas. Em

particular, a relação entre o desmatamento acumulado nas últimas décadas e limiares que causam perdas hidrológicas.

(2) Avaliar como as mudanças climáticas locais e regionais futuras (associadas ao desmatamento) influenciarão nas perdas de produtividade das lavouras de soja e pastagens no Sul da AM Brasileira e estimar as perdas econômicas potenciais. **Motivação:** Estudos sugerem que mudanças no padrão de precipitação e temperatura podem reduzir a produção agrícola. No entanto, as interações entre o desmatamento e produtividade de soja e pastagens ainda permanecem pouco conhecidas, bem como seus impactos econômicos ainda não foram plenamente quantificados.

(3) Estimar os riscos de mudanças climáticas regionais (Redução do volume de chuvas, atraso no início da estação chuvosa e aquecimento do ar) sob diferentes níveis de desmatamento no CE e na AM durante as janelas de cultivo da primeira e segunda safras (Soja e milho) que resultam em alterações significativas na produtividade das lavouras. **Motivação:** O sistema de dupla safra soja-milho depende fortemente dos recursos naturais e por isso é uma atividade de alto risco. Atualmente, esses riscos são ainda maiores pois a agricultura contemporânea se caracteriza pelo uso intensivo do capital. No entanto, os riscos agroclimáticos associados ao desmatamento da AM e CE ainda não foram plenamente quantificados.

(4) Quantificar a relação entre mudanças na cobertura florestal acumulada e mudanças nos padrões de temperatura máxima e mínima no CE e na AM nas últimas duas décadas. **Motivação:** Modificações no balanço de energia decorrentes do desmatamento podem alterar padrões de temperatura máxima e mínima. No entanto, as interações entre o desmatamento e os padrões de temperatura nas últimas duas décadas ainda permanecem pouco quantificadas.

(5) Quantificar a relação entre mudanças na cobertura florestal acumulada e mudanças nos padrões precipitação no CE e na AM nas últimas duas décadas. **Motivação:** Modificações no balanço de energia e na evapotranspiração decorrentes do desmatamento podem alterar o volume de chuvas e o início da estação chuvosa nas regiões tropicais. No entanto, as interações entre o desmatamento e os padrões de precipitação nas últimas duas décadas ainda permanecem pouco quantificadas.

(6) Estimar as perdas de produção da soja e do milho e as perdas econômicas potenciais decorrentes das quebras de safra ocorridas nas últimas décadas no CE e na AM. **Motivação:**

Perdas na produção agrícola estão fortemente atreladas a eventos de secas e ondas de calor. Com as mudanças climáticas globais, regionais e locais, diversos modelos climáticos predizem mudanças climáticas acentuadas nas maiores áreas produtoras de grãos do país. Conseqüentemente, as quebras de safra provocam prejuízos bilionários no campo e pressionam os preços dos alimentos.

(7) Identificar os determinantes espaciais causas das quebras e ganhos de produtividade das quebras de safra ocorridas nas últimas décadas no CE e na AM Brasileira. **Motivação:** Muitos fatores podem interferir na produtividade (fatores econômicos, mercadológicos e políticos). A partir da identificação determinantes causais das quebras de produtividade, muitas das relações indiretas ou não óbvias, mas que influenciam significativamente a ocorrência de quebras ainda precisam ser identificadas.

(8) Estimar as perdas de produção da soja e do milho e as perdas econômicas potenciais decorrentes das quebras de safra que estão ligadas diretamente ou indiretamente ao desmatamento do CE e da AM Brasileira nas últimas décadas. **Motivação:** Pesquisas ligam o avanço da agropecuária em biomas como AM e CE a estiagem e alta nas temperaturas, o que, reduz a produtividade e resulta em bilhões de dólares de prejuízo por ano ao setor.

(9) Estimar os impactos econômicos diretos e indiretos do desmatamento do Cerrado e da AM Brasileira na receita atingida com as exportações de grãos entre 2006 e 2019. **Motivação:** O mercado global de milho e soja é dividido por apenas quatro países: Brasil, Argentina, Estados Unidos e a Ucrânia. Este último, por conta da guerra, reduziu a oferta de grãos no mercado internacional. No Brasil, o CE e a AM abrigam a maior parte da agricultura voltada para a exportação. A maioria dos produtores que adotam o sistema dupla-safra soja-milho decidem exportar ambas as safras.

3 ESCOPO DA TESE

Os artigos científicos provenientes deste estudo são apresentados em três capítulos (1 publicado, 1 submetido e 1 em preparação) que correspondem, respectivamente, aos capítulos 1, 2 e 3 (Figura 3.1):

- **Capítulo 1:** Deforestation reduces rainfall and agricultural revenues in the Brazilian Amazon;
- **Capítulo 2:** Desmatamento agrava o risco agroclimático no Cerrado e na Amazônia Brasileira;
- **Capítulo 3:** A conta do desmatamento e da variabilidade climática para o Agronegócio Brasileiro.

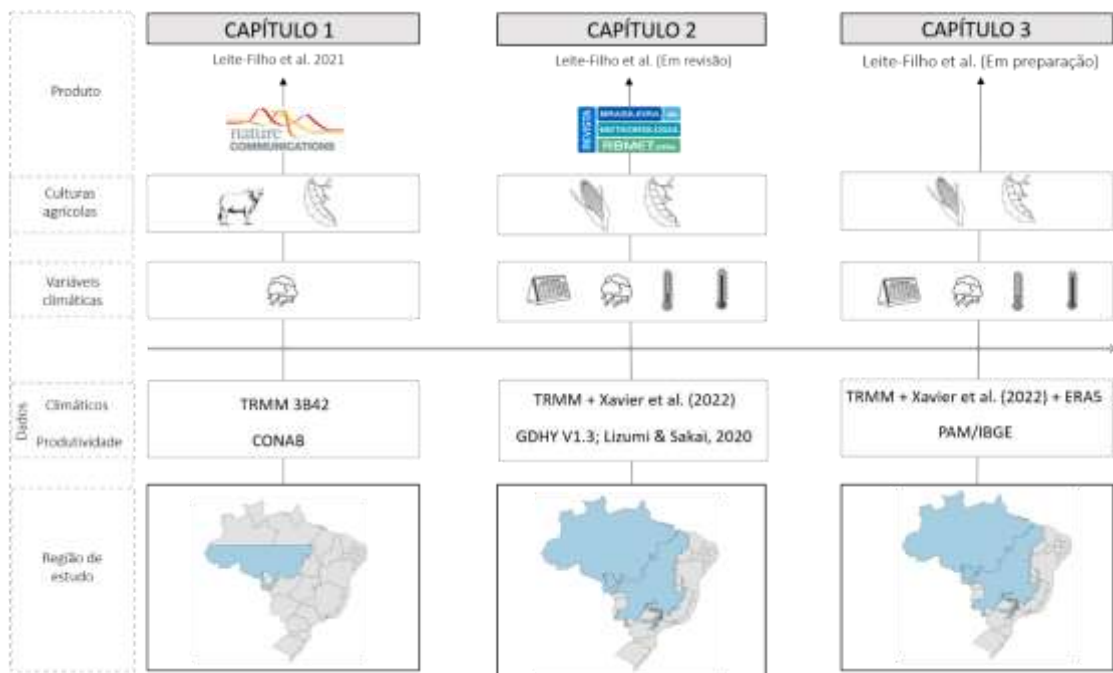


Figura 3.1: Estrutura da tese e produtos associados

À luz da Agenda 2030 para o Desenvolvimento Sustentável da ONU, 5 Objetivos do Desenvolvimento Sustentável (ODS) se integram de forma ampla com esta tese. Todos os pontos visam o incentivo à sustentabilidade como o caminho para garantir os serviços ecossistêmicos que irrigam a produção agrícola no Brasil. São eles:

- **ODS 2 (Acabar com a fome, alcançar a segurança alimentar e melhoria da nutrição e promover a agricultura sustentável):** Esta tese pode contribuir para a discussão sobre os impactos dos sistemas de produção de alimentos de forma a incentivar práticas agrícolas resilientes, que aumentem a produtividade e a produção, que ajudem a manter os ecossistemas, que fortaleçam a capacidade de adaptação às mudanças climáticas, às condições meteorológicas extremas, secas e outros desastres.
- **ODS 6 (Assegurar a disponibilidade e gestão sustentável da água e saneamento para todas e todos):** Esta tese reforça a necessidade de proteção e restauração de ecossistemas relacionados com a água no que concerne ao enfrentamento das condições de seca, incluindo a Floresta Amazônia e as savanas do CE.
- **ODS 12 (Assegurar padrões de produção e de consumo sustentáveis até 2030, alcançar a gestão sustentável e o uso eficiente dos recursos naturais):** Os resultados aqui apresentados podem contribuir para traçar caminhos visando alcançar a gestão sustentável e o uso eficiente dos recursos naturais, fortalecendo a capacidade científica do País em direção a padrões mais sustentáveis de produção.
- **ODS 13 (Tomar medidas urgentes para combater a mudança climática e seus impactos):** Este estudo reforça a necessidade de se integrar medidas da mudança do clima nas políticas, estratégias e planejamentos nacionais. Este documento pode aumentar a conscientização sobre mitigação, adaptação e redução de impactos climáticos.
- **ODS 15 (Proteger, restaurar e promover o uso sustentável dos ecossistemas terrestres, gerir de forma sustentável as florestas, combater a desertificação, travar e reverter a degradação dos solos e travar a perda da biodiversidade):** Esta tese apresenta evidências substanciais que podem funcionar como potenciais incentivadores para a implementação da gestão sustentável da AM e CE, de forma a deter o desmatamento, restaurar florestas degradadas e aumentar substancialmente o reflorestamento.

4 CAPÍTULO 1

DEFORESTATION REDUCES RAINFALL AND AGRICULTURAL REVENUES IN THE BRAZILIAN AMAZON

Artigo publicado

Leite-Filho, A. T., Soares-Filho, B. S., Davis, J. L., Abrahão, G. M. & Börner, J. Deforestation reduces rainfall and agricultural revenues in the Brazilian Amazon. *Nature Communications* 12, 2591 (2021).

Resumo

A literatura científica tem apontado a diminuição da precipitação na Amazônia se a perda de floresta exceder algum limite, mas o valor específico desse limite permanece incerto. Neste artigo investigamos a relação entre o desmatamento histórico e o volume anual de chuvas em diferentes escalas geográficas no Sul da Amazônia Brasileira (SBA). Adicionalmente avaliamos os impactos futuros de diferentes cenários de política de desmatamento e expansão da agricultura da região. A perda de floresta até 55-60% em pixels de 28 km x 28 km de resolução espacial aumenta a precipitação, mas o desmatamento adicional reduz a precipitação precipitadamente. Este limite é menor em escalas geográficas maiores (45-50% em pixels de 56 km e 25-30% em pixels de 112 km de resolução espacial), enquanto a precipitação diminui linearmente em regiões de 224 km x 224 km. O desmatamento generalizado resulta em um jogo de soma hidrológica e econômica negativa, já que menores volumes de chuvas e as perdas de produtividade agrícola em escalas maiores superam os ganhos locais. Em um cenário de governança ambiental fraca, a SBA pode perder 56% de suas florestas até 2050. A redução do desmatamento na região evita perdas agrícolas de até US\$ 1 bilhão por ano.

4.1 INTRODUCTION

Mounting evidence from model-based and empirical research indicates that the Amazon Forest influences the spatiotemporal patterns and amount of rainfall (COSTA; PIRES, 2010; BOERS *et al.*, 2017; LEITE-FILHO; PONTES; COSTA, 2019; LEITE-FILHO; COSTA; RONG, 2019b). Among the multiple forest ecosystem services, rainfall regulation is key to sustain agriculture in the region and beyond (COSTA *et al.*, 2019), where an important share of Brazil's soy and beef is produced. Despite this well-documented function, deforestation in the Brazilian Amazon is on the rise again. As of 2020, INPE; PRODES, 2020 reported 11 thousand km² of forest loss, a 143% increase from 2012, the lowest deforestation rate on record. As forest loss accumulates, impacts on rainfall patterns may critically affect agriculture, especially in the Southern Brazilian Amazon (SBA), where forest losses already amount to 30% (INPE; PRODES, 2020). SBA is one of the most dynamic land-use frontiers in the world (FAO, 2006) and accounts for the lion's share of croplands and pastures in the Brazilian Amazon (Figure 4.1).

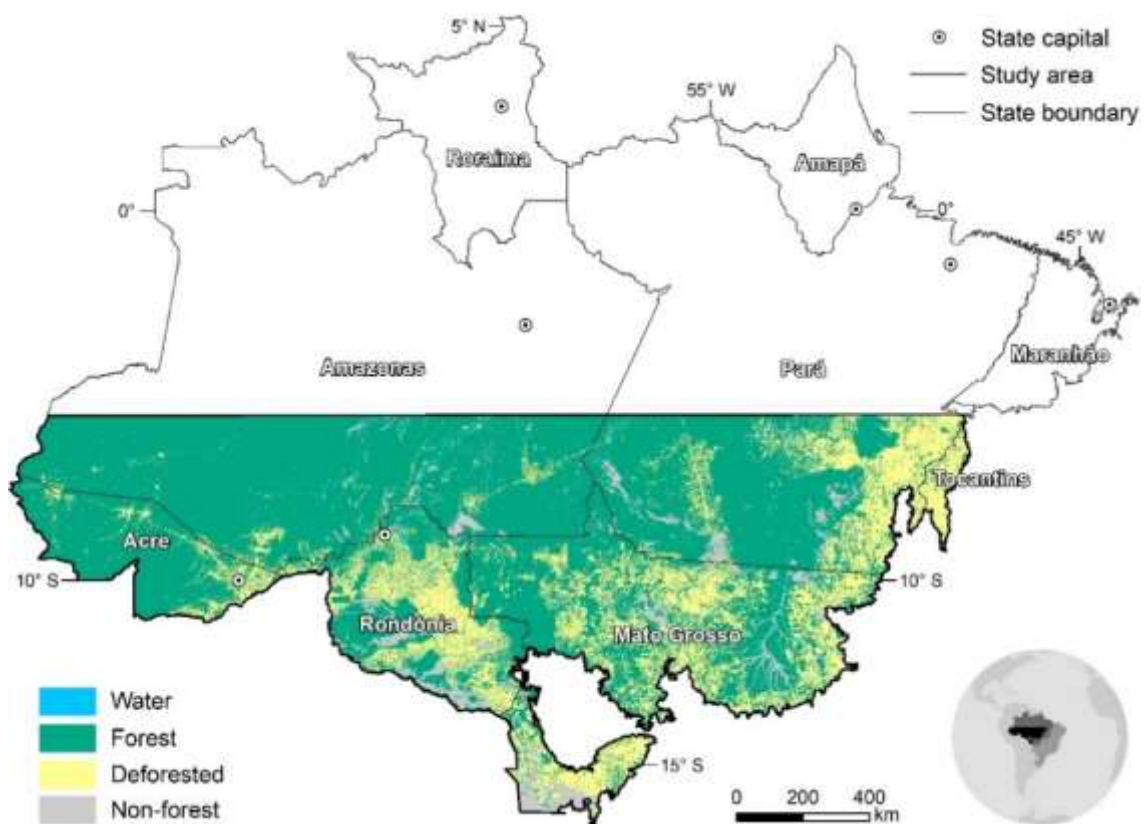


Figure 4.1: Land cover in the Southern Brazilian Amazon as of 2019. Southern Brazilian Amazon encompasses 1.9 million km² of the Amazon biome. Deforested area by 2019 according to Program to Calculate Deforestation in the Amazon (PRODES).

Despite extensive research on greenhouse gas (GHG) induced climate change (IPCC, 2015), few studies have addressed regional climate change in response to extensive land use and cover change (LUCC), such as deforestation. Forest conversion to pasture and croplands (forest loss) affects moisture cycling and energy balance (COSTA *et al.*, 2007; SHEIL; MURDIYARSO, 2009) and may change rainfall patterns (LEITE-FILHO; PONTES; COSTA, 2019a; LEITE-FILHO; COSTA; RONG, 2019b; AGUDELO *et al.*, 2019; MOLINA *et al.*, 2019) Hence, the regional climate could respond as much as or even stronger to LUCC than to global warming (PONGRATZ *et al.*, 2010; NOBLET *et al.*, 2012). In the Amazon, the estimated impact on the annual radiative budget due to surface albedo-change is approximately 6 times higher than that of aerosol emissions, and projected impacts on agriculture from future deforestation-induced changes in climate are of the same magnitude as those from global climate change under the RCP 8.5 scenario (SENA; ARTAXO; CORREIA, 2013)

Studies point to a reliance of the Amazon regional rainfall regimes on the forest (FU; LI, 2004; MAKARIEVA; GORSHKOV, 2007 RAMOS-DA-SILVA *et al.*, 2011). Although the effects of biome-wide deforestation affecting forest moisture recycling and irreversible biome transition are still relatively uncertain (BAGLEY *et al.*, 2014; KHANNA *et al.*, 2017; SWANN *et al.*, 2015), at smaller geographical scales some studies suggest a negative linear response of rainfall to forest loss (AKKERMANS; THIERY; LIPZIG, N. , 2014), while others indicate a nonlinear response (BOERS *et al.*, 2017; SAMPAIO *et al.*, 2007; DA SILVA; WERTH; AVISSAR, 2008; LAWRENCE; VANDECAR, 2014). According to the latter, small scale, patchy, heterogeneous deforestation patterns drive changes in mesoscale circulation of moisture flow from forests into the atmosphere that can enhance precipitation over nearby deforested areas (KHANNA *et al.*, 2017; LAWRENCE; VANDECAR, 2014; MAKARIEVA; GORSHKOV; LI, 2009). However, as forest loss progresses, the region eventually reaches a critical threshold beyond which this relationship reverses with additional forest loss rapidly reducing rainfall (COSTA *et al.*, 2007; SAMPAIO *et al.*, 2007; NOBRE *et al.*, 2009; SAAD *et al.*, 2010).

At regional scales (\approx 200-600 km grid-cell size), modelling experiments indicate that the critical threshold of forest loss beyond which rainfall progressively decreases lies between 30% and 50% of forest loss, depending on the spatial patterns of deforestation (SAMPALIO *et al.*, 2007; NOBRE *et al.*, 2009). But to date, no study has empirically identified this critical threshold and the consequences of crossing it by using observed rainfall data.

In this work, we fill this gap by detrending the effects of geographic location, elevation and interannual variability on a satellite-derived rainfall time-series to correlate the residual anomalies with forest loss at different geographical scales (28 to 224 km grid-cell sizes). To gauge future critical thresholds of forest loss and associated agricultural economic losses, we use projections of agricultural expansion in the region under weak and strong environmental governance scenarios and estimates of soybean and pasture yield losses due to rainfall reduction caused by deforestation across the Brazilian Amazon.

4.2 RESULTS AND DISCUSSION

4.2.1 Relationship between deforestation and rainfall at different geographical scales

The relationship between forest loss fractions and annual mean rainfall anomalies at 28, 56 and 112 km grid cells cannot be explained by using a single linear regression, the best fit was obtained by adjusting a multivariate adaptive regression spline (MARS) composed of two piecewise linear segments (Figures 4.2a-f). In turn, the best fit for the 224x224 km grid cells was attained by a single linear regression.

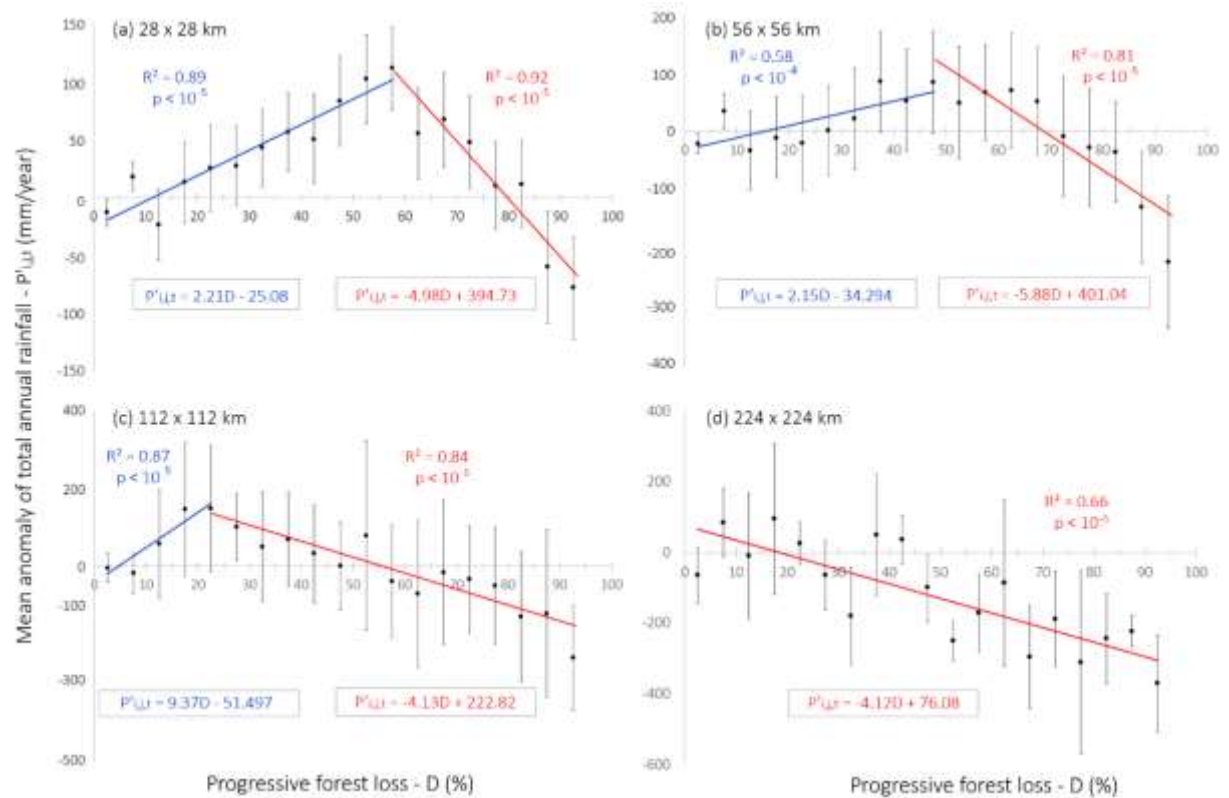


Figure 4.2: Mean annual rainfall anomalies per forest loss percent within 28, 56, 112 and 224 km grid cells. Two piecewise linear segments from MARS algorithm: a) $D < 57.5\%$ (blue line) and $D \geq 57.5\%$ (red line) for 28 km grid cells, b) $D < 47.5\%$ (blue line) and $D \geq 47.5\%$ (red line) for 56 km grid cells, c) $D < 27.5\%$ (blue line) and $D \geq 27.5\%$ (red line) for 112 km grid cells, d) best fit linear model (dashed red line) for 224 km grid cells. Error bar represents the standard error of the mean rainfall anomaly for each forest loss interval. $P'_{i,j,t}$ are the residual annual rainfall anomalies (in mm/year), where the subscripts i and j represent space dimensions and the subscript t represent time dimension. D represents the progressive forest loss fraction (in percentage).

Forest loss affects rainfall differently depending upon the geographical scale (Figure 4.22a-d). At the original spatial resolution of the TRMM data (28x28 km grid cell), there is a dual effect of forest loss, with rainfall increasing with forest loss up to $\approx 58\%$ and then decreasing afterwards (Figure 4.22a). The gain before the critical threshold is of $+22.1 \pm 9.3$ mm of precipitation per each 10% of additional forest loss. However, beyond 57.5% of forest loss, precipitation reduces precipitously, with each 10% of additional forest loss inducing a net reduction in annual rainfall of -49.2 ± 11.3 mm.

We tested for correlation between forest loss and the mean long-term trend in rainfall using t-tests. The test comparing the annual rainfall between cells with smaller forest loss and

cells that experienced larger forest loss within two separated periods: 1999–2009 and 2010–2019 (Supplementary Table 6) demonstrated that the cells with smaller historical forest loss (below 55-60%) experienced an increase in annual rainfall by $+96.9 \pm 12.65$ mm. Conversely, cells with larger forest losses (exceeding 55-60%) exhibited an annual decrease of -306.4 ± 42.77 mm (Supplementary Table 7). Both statistical Inferences were statistically significant with $p < 0.05$.

Aggregating both forest loss and rainfall data to a coarser scale (56x56 km grid cell), the critical threshold dropped to $\approx 48\%$ (Figure 4.2b). For 112x112 km grid cells, both the positive and negative effects were attenuated and the threshold reduced even more to $\approx 23\%$ of forest loss (Figure 4.2c). This dual response of rainfall to forest loss is consistent with the theory and climate modelling experiments (DA SILVA; WERTH; AVISSAR, 2008). At smaller geographical scales (28 and 56 km), the reduction in rainfall after the critical threshold was more than twice as fast as the increase before the threshold. However, at larger geographical scales this effect attenuated until we found a constant linear reduction at 224x224 km grid cells (Figure 4.2d).

Our multi-scale analysis supports the argument that, if neighboring grid cells also have high levels of forest loss, the critical threshold of forest loss kicks in at a lower level of forest loss. Therefore, widespread deforestation results in a negative-sum game where total reduction in rainfall outdoes local gains. In this sense, the critical thresholds we found within smaller grid cells are conservative because as regional deforestation progresses, local gains diminish and eventually cancel out.

At the scale from 28 to 56 km, the land-cover heterogeneity forms anomalous meteorological vertical cells, with enhanced convection and hence increased rainfall over part of the deforested patch and rainfall suppression over the surrounding forested regions, what is known as rainfall dipoles (KHANNA *et al.*, 2017). The location, size, strength and net effect of the rainfall dipoles are heavily influenced by the size of the deforested patch, large-scale winds, and surrounding forested area (KHANNA *et al.*, 2017; SAAD *et al.*, 2010).

On the other hand, the reduction in rainfall at a larger geographical scale (224x224 km) is caused by a combination of higher albedo of deforested surfaces and the smaller year-round evapotranspiration of crops and pastures relative to natural vegetation (LAWRENCE; VANDECAR, 2014). The former effects in addition to reduced surface roughness, which in

turn diminishes the vertical transport of turbulence by horizontal winds (LAWRENCE; VANDECAR, 2014; DICKINSON; KENNEDY, 1992), decreases atmospheric moisture available for precipitation. In this respect, SENA; ARTAXO; CORREIA, 2013 indicate that precipitable water above deforested areas is $\approx 7\%$ lower than that above the Amazon Forest. Thus, the critical threshold is the point after which the combined effects of the higher albedo, smaller evapotranspiration and reduced surface roughness due to forest loss become stronger than the deforestation breeze effect, which weakens with forest loss. The net reduction we find after the critical threshold is much steeper than the prior net gains, which is consistent with climate modelling results (LAWRENCE; VANDECAR, 2014; SAAD *et al.*, 2010).

The quantitative effects of forest loss on rainfall are for the study region as whole. Particular grid cells may be more or less affected according to their locations. The smallest interannual variability is verified in grid cells located in the south and southwest of the Amazon (Supplementary Figure 4.7), where the annual rainfall is lower (Supplementary Figure 4.1). Consequently, rainfall reduction due to forest loss is proportionally larger in those regions, currently reaching up 48% (Supplementary Figure 4.8). This has economic implications for agriculture since the areas most affected by rainfall reduction are major soy production zones or regions where agriculture is likely to expand in the future (Supplementary Figure 4.9). Crop yields and the success of double cropping systems already vary significantly from year to year in SBA because of the interannual climate variability (COHN *et al.*, 2016; ABRAHÃO; COSTA, 2018). The effect of forest loss on rainfall superimposed to the interannual variability thus poses an additional risk of crop failure in dry or drought years, which tend to become more frequent and intense as deforestation progresses alongside climate change (Supplementary Section 2.1).

4.2.2 Additional evidence for forest loss causation of rainfall reduction

The relationship between forest loss and rainfall presented here is correlational. To demonstrate that this relationship is significantly greater than a potentially reverse causal effect, i.e. more severe deforestation systematically taking place in drier (or drying) parts of the forest, we superimposed a map of the effects of Maximum Climatological Water Deficit on deforestation (AGUDELO *et al.*, 2019; STAAL *et al.*, 2020) over our study region. We found that only 12 cells of a total 86 non-null cells (14% of our study region) showed a statistically significant effect that more severe forest loss tends to take place in drier (or drying) parts

(Supplementary Figure 4.11). However, the signal in these few grid cells was near zero. Although the feedback between drought and forest loss is notable in more humid regions of the Amazon that lack a marked dry season (STAAL *et al.*, 2020), this is not the case for SBA, where the dry season is longer than 150 days (AGUDELO *et al.*, 2019), hence sufficiently long to dry out the chopped down understory vegetation and completely clear-cut the forest. In addition, empirical evidence suggests that the length of the rainy season decreases $\approx 0.9 \pm 0.34$ days for each additional 10% of forest loss (LEITE-FILHO; COSTA; RONG, 2019b).

Finally, we measured the spatial association between rainfall anomalies and forest loss by calculating the Cramer's V (CRAMÉR, 1946) and the Spearman Rank Order Correlation coefficient (SPEARMAN, 1904). After detrending the other signals, the resulting anomalies exhibited a spatial variability that correlated only with forest loss (Supplementary Figure 4.10), which corroborates the hypothesized causal direction from forest loss to rainfall reduction in SBA.

4.2.3 Future critical forest loss thresholds and associated agricultural economic losses

To assess the impacts of future regional rainfall reduction on agriculture, we simulated deforestation across SBA. To do so, we ran Otimizagro (SOARES-FILHO *et al.*, 2016; ROCHEDO *et al.*, 2018), a countrywide LUC model for Brazil, from 2015 to 2050 under two alternative policy scenarios, i.e. weak and strong environmental governance (ROCHEDO *et al.*, 2018) (Supplementary Section 4.4.5). The weak governance scenario (WEG) assumed the continued dismantling of Brazil's conservation policies along with strong political support for environmentally damaging agricultural practices and implicit economic incentives for illegal deforestation (Supplementary Section 4.4.5.1). The strong governance (SEG) scenario incorporated effective enforcement of conservation policies based on a sustained political support for the environmental agenda in Brazil, including the full implementation of the Forest Code and additional conservation incentives (ROCHEDO *et al.*, 2018; RAJÃO *et al.*, 2020) (Supplementary Section 4.4.5.2).

As of 2019, 25% of SBA had already reached the 55-60% threshold of forest loss within 28x28 km grid cells. This critical threshold under the WEG would occur in 36% and 55% of the region's grid cells by 2030 and 2050, respectively (Figure 4.3). The realization of the SEG scenario could abate by 24% the number of grid cells that would reach the critical threshold by 2050 under the WEG. At coarser scales (56 km and 112 km) the critical threshold of forest loss

($D \geq 47.5\%$ and $D \geq 27.5\%$) under the WEG would occur in 61% and 69% of the region's grid cells by 2050, respectively. Again, the full implementation of the SEG scenario could abate by 28% and 16% the number of 56 and 112 km grid cells, respectively, that would reach the critical threshold of forest loss by 2050 under the WEG.




Figure 4.3: Percentage of different grid-cell sizes crossing the critical threshold. Percentage of different grid-cell sizes crossing the critical threshold of forest loss in southern Brazilian Amazon over time under the two environmental governance scenarios: Weak scenario (WEG), and Strong scenario (SEG) within 28 km, 56 km and 112 km grid cells.

Similar to other tropical regions, agriculture in the Amazon is mostly rainfed (SUMILA *et al.*, 2017), and as such decreases in annual rainfall in response to forest loss will reduce yields or shift agriculture either away from the region or toward more drought-resistant crops. Forest suppression also delays the onset of the rainy season (LEITE-FILHO; PONTES; COSTA, 2019a; LEITE-FILHO; COSTA; RONG, 2019b; DEBORTOLI *et al.*, 2016) prepones its end (LEITE-FILHO; COSTA; RONG, 2019b; DEBORTOLI *et al.*, 2016), and shortens its length (LEITE-FILHO; COSTA; RONG, 2019b; BARICHIVICH *et al.*, 2018). All these rainy season characteristics are essential for the highly productive double cropping systems in the region (COHN *et al.*, 2019; ABRAHÃO; COSTA, 2018). Hence, continued deforestation imposes

major challenges for agricultural production in SBA, especially in regions that have already reached the critical threshold of forest loss within the 28x28 km grid cells, such as the north-eastern and south-eastern regions of Pará State, West of Maranhão State, the central part of Rondônia and, most notably, the northern soybean belt in Mato Grosso State (Figures 4.4d- f).

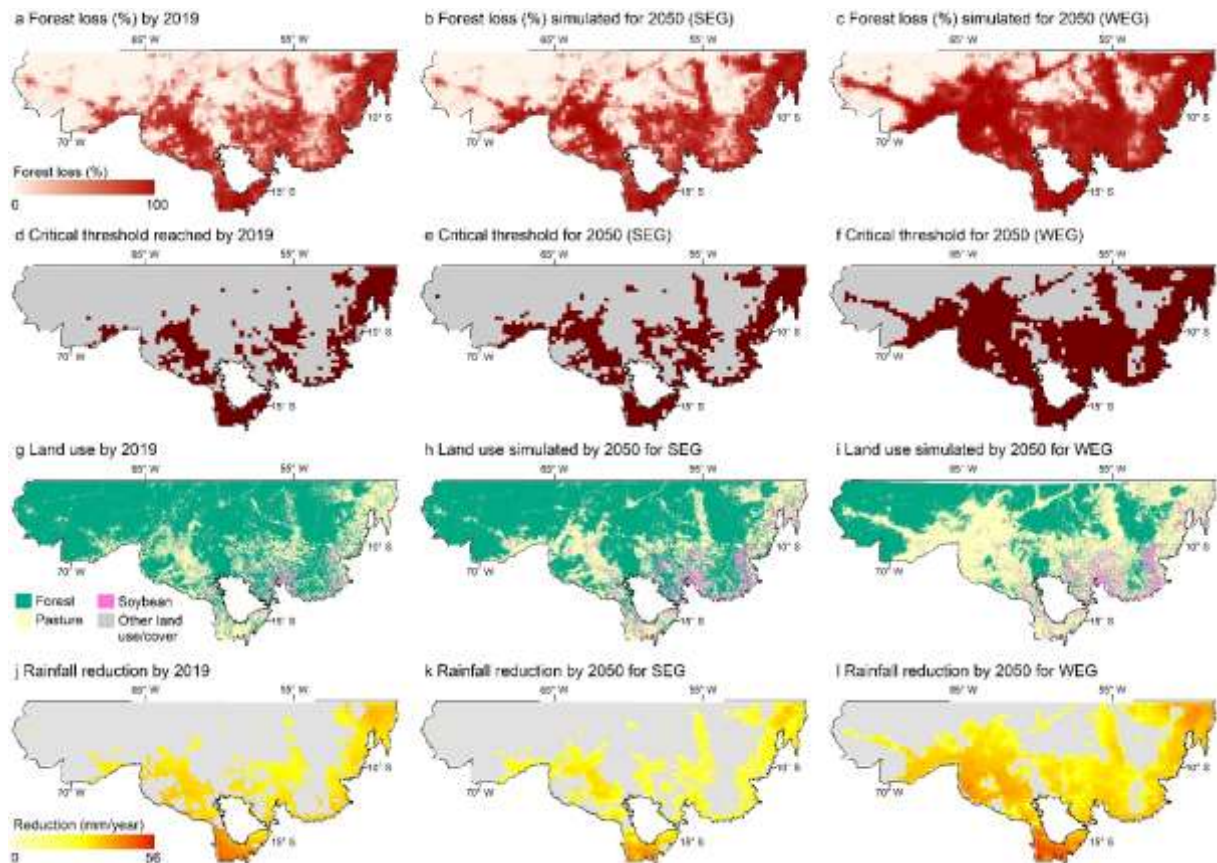


Figure 4.4: a-c) Percentage of forest loss, d-f) 28x28 km grid cells reaching the critical threshold, g-i) land use/cover and j-l) rainfall reduction. Percentage of forest loss: a) by 2019, b) simulated for 2050 for SEG and c) WEG. 28x28 km grid cells reaching the critical forest loss threshold: d) by 2019, e) simulated by 2050 for SEG, f) and WEG scenario. Land use/cover: g) by 2019, h) simulated by 2050 for SEG, i) and WEG. Rainfall reduction: j) by 2019, simulated by 2050 for k) SEG and l) WEG.

To gauge the potential agricultural economic losses implied by our two scenarios, we used the projections of agricultural expansion in the region for the SEG and WEG scenarios from the Otimizagro model (ROCHEDO *et al.*, 2018) and estimates of soybean and pasture yield losses due to rainfall reduction caused by deforestation across the Brazilian Amazon (STRAND *et al.*, 2018). Our goal was to explore whether the hydrological zero-sum game outlined above equivalently applies to the economics of agricultural expansion in the region. If

so, the opportunity costs, in terms of foregone revenues from converting less forest to crop and pasturelands in the SEG scenario, would have to be outperformed by losses in crop and pasture productivity across SBA due to changes in rainfall patterns under the WEG (Supplementary Section 1.6).

Considering only revenues from soy cultivation and beef production in SBA, we find that productivity losses and associated revenues under WEG (US\$ 5.6 billion for soy and US\$ 180.8 billion for beef production by 2050 in Net Present Values - NPV) dwarf the conservation opportunity costs of US\$ 19.5 billion in NPV under SEG. In other words, Brazil may have passed a threshold at which further Amazon deforestation translates into direct economic damage. Deforestation does not only result in CO₂ emissions and irreversible loss of globally valued biodiversity; it also imposes massive productivity losses worth up US\$ 1 billion annually (Equivalent Annual Annuity; Supplementary Section 4.4.6) on the region's agribusiness. And it is unlikely, at least in the short or medium term, that accounting for adaptation costs and potential benefits would tip the balance in favour of agricultural expansion.

Anticipating the impacts of deforestation on the Amazon ecosystem services, especially regarding rainfall regulation for agriculture, is paramount to convince policy makers and other stakeholders to act before it is too late. Indeed, acknowledging those risks could help steer Brazil back to a course that sustainably integrates agricultural production and environmental conservation. Brazil's agribusiness and their global partners are testing the limits of nature by expanding into natural forests at the risk of reducing the rainfall that sustains its productivity. The current land-use trajectory in the Brazilian Amazon therefore puts the largely rainfed agricultural systems of the country on a path towards an "agro-suicide".

4.3 METHODS

We analysed the quantitative linkage between annual rainfall and Amazon Forest loss from 1999 to 2019. Using a multi-scale approach, we empirically determined the level of forest loss (the critical threshold) beyond which the effect of forest loss on rainfall reverses. Our approach sheds light on the unresolved question as to how continued forest loss affects annual rainfall at different geographical scales. We also explored when and which regions in SBA may

reach the critical threshold of forest loss under two environmental governance scenarios (SEG and WEG) (ROCHEDO *et al.*, 2018).

Region. SBA covers 1.9 million km². This region historically underwent agricultural and logging expansion from the south and east of Brazil.

Rainfall data. We used the rainfall data between 1999 and 2019 from the Tropical Rainfall Measuring Mission satellite (TRMM) 3B43 product (version 7). Monthly rainfall was aggregated to obtain yearly rainfall. TRMM data are originally at $\approx 28 \times 28$ km spatial resolution. This rainfall dataset has been extensively verified and validated for the Amazon biome (ARAGÃO *et al.*, 2007; BALLARI; CASTRO; CAMPOZANO, 2016).

Deforestation data. We used data from PRODES (Program to Calculate Deforestation in the Amazon) (INPE; PRODES, 2020), originally released at ≈ 30 m spatial resolution. We aggregated PRODES data into time-series maps of percentages of forest loss per grid-cell sizes from 28×28 km, 56×56 , 112×112 to 224×224 km.

Anomalies of annual rainfall. Rainfall in the region has a marked spatial gradient (Supplementary Figure 4.1) and interannual variability. Thus, to minimize omitted variable bias in our analysis, we firstly removed the effects of factors other than deforestation that may affect rainfall across both time and space. To do so, we calculated anomalies of annual rainfall using a 3-step procedure (Supplementary Figure 4.4), based on a conceptual methodology developed for analysing the onset, end and length of the rainy season in Southern Amazon (LEITE-FILHO; COSTA; RONG, 2019b). We calculated anomalies of annual rainfall ($P'_{i,j,t}$) using the 3-step procedure summarized in Eqs. (1), (2) and (3) and Supplementary Figure 4.4. Notations are as follows: i, j, t are the subscripts representing space (i, j) and time (t); $P_{i,j,t}$ are the annual rainfall values in mm; $\hat{P}_{i,j}$ are the estimated values of rainfall due to geographical location and elevation; $P^*_{i,j,t}$ is the difference between observed annual rainfall values and the estimated ones due to geographical location and elevation; \bar{P}_t are the annual averages of rainfall calculated throughout the study region calculated from 1999 to 2019; $P'_{i,j,t}$ are the residual annual rainfall anomalies and φ, λ, ζ are latitude, longitude (in *degrees*) and elevation (in meters).

Step 1: To estimate the spatial pattern of annual rainfall, we used a second-degree model ($r^2 = 0.72$; $p > 10^{-5}$) to compute estimated values of rainfall due to this geographical pattern so that:

$$\hat{P}_{i,j} = -8340 + (27.55\varphi) + (-1.359\varphi^2) + (-366.2\lambda) + (-3.005\lambda^2) + (-2.118\zeta) + (0.003\zeta^2) \quad (1)$$

Step 2: To remove the climatological trend related to geographic location and elevation, we calculated the difference between raw values of observed rainfall in each year and the estimated values due to geographical position obtained from Eq. (1), so that:

$$P_{*i,j,t} = (P_{i,j,t} - \hat{P}_{i,j}) \quad (2)$$

Step 3: To remove the signal of large-scale factors, such as that of the ENSO, we subtracted the mean annual rainfall for the whole study region from the outputs of Eq. (2):

$$P'_{i,j,t} = P_{*i,j,t} - \bar{P}_t \quad (3)$$

The residual is assumed to be an “anomaly” that is not explained by the geographic location, elevation or large-scale time-varying factors.

LUCC modelling and associated agricultural economic impact. Otimizagro is a spatially-explicit model that simulates land use, land-use change, forestry, deforestation, and regrowth under various scenarios of agricultural land demand and deforestation policies for Brazil (SOARES-FILHO *et al.*, 2016). The model simulates nine annual crops (including single and double cropping); five perennial crops, and plantation forests. The model framework, developed using the Dinamica EGO platform (dinamicaego.com), is structured in four spatial levels: (i) Brazil's biomes, (ii) IBGE micro-regions, (iii) Brazilian municipalities, and (iv) a raster grid of 25 ha spatial resolution. Future demand for crops and deforestation, and regrowth rates are exogenous to the model. We assumed constant agricultural practices and prices over time under both governance scenarios. Opportunity costs are calculated as follows:

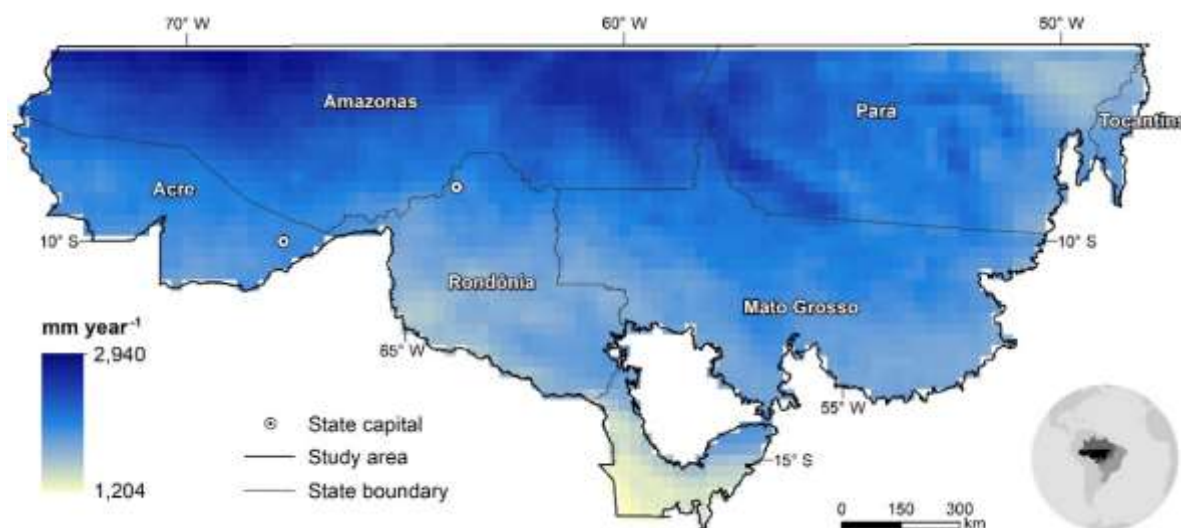
(I) We performed simulation of deforestation in the Brazilian Amazon as well as soybean and pasture expansion under the SEG and WEG scenarios (ROCHEDO *et al.*, 2018). (II) We calculated the average productivity using regional estimates of soybean and pasture yield losses due to rainfall reduction caused by Amazon biome-wide deforestation (STRAND *et al.*, 2018) (Supplementary Section 1.6). (III) We projected productivity change until 2050 adjusting future soybean yields projections (3.7 ton/hectare) (MINISTÉRIO DA AGRICULTURA, 2019) and pasture productivity projections (BATISTA *et al.*, 2019) (2.9

arroba/hectare) (BATISTA *et al.*, 2019) by the average productivity losses calculated in step II. (IV) We computed annual revenues in US\$ per hectare using current soybean and *cattle arroba* prices (US\$ 302.58 per ton and US\$ 201.50 per arroba, respectively) and projected soybean and pasture productivity for each of the two deforestation scenarios with and without decreases in yields. Under each scenario, total annual revenues are calculated by weighting soy and pasture revenues using the simulated future area under crops and pastures. (V) We calculated the Net Present Value of future revenues for SBA using as the discount rate the Selic interest rate of 3.75% (the Selic is determined by Brazil's Central Bank) and converted NPV into Equivalent Annual Annuity (EAA; Supplementary equation 15). (VI) The difference between the total NPV of revenues under the WEG versus the SEG scenario is the opportunity cost of the SEG scenario. Similarly, the difference between EAA of revenues under the WEG versus the SEG scenario is the annual opportunity cost of the SEG scenario.

4.4 SUPPLEMENTARY METHODS

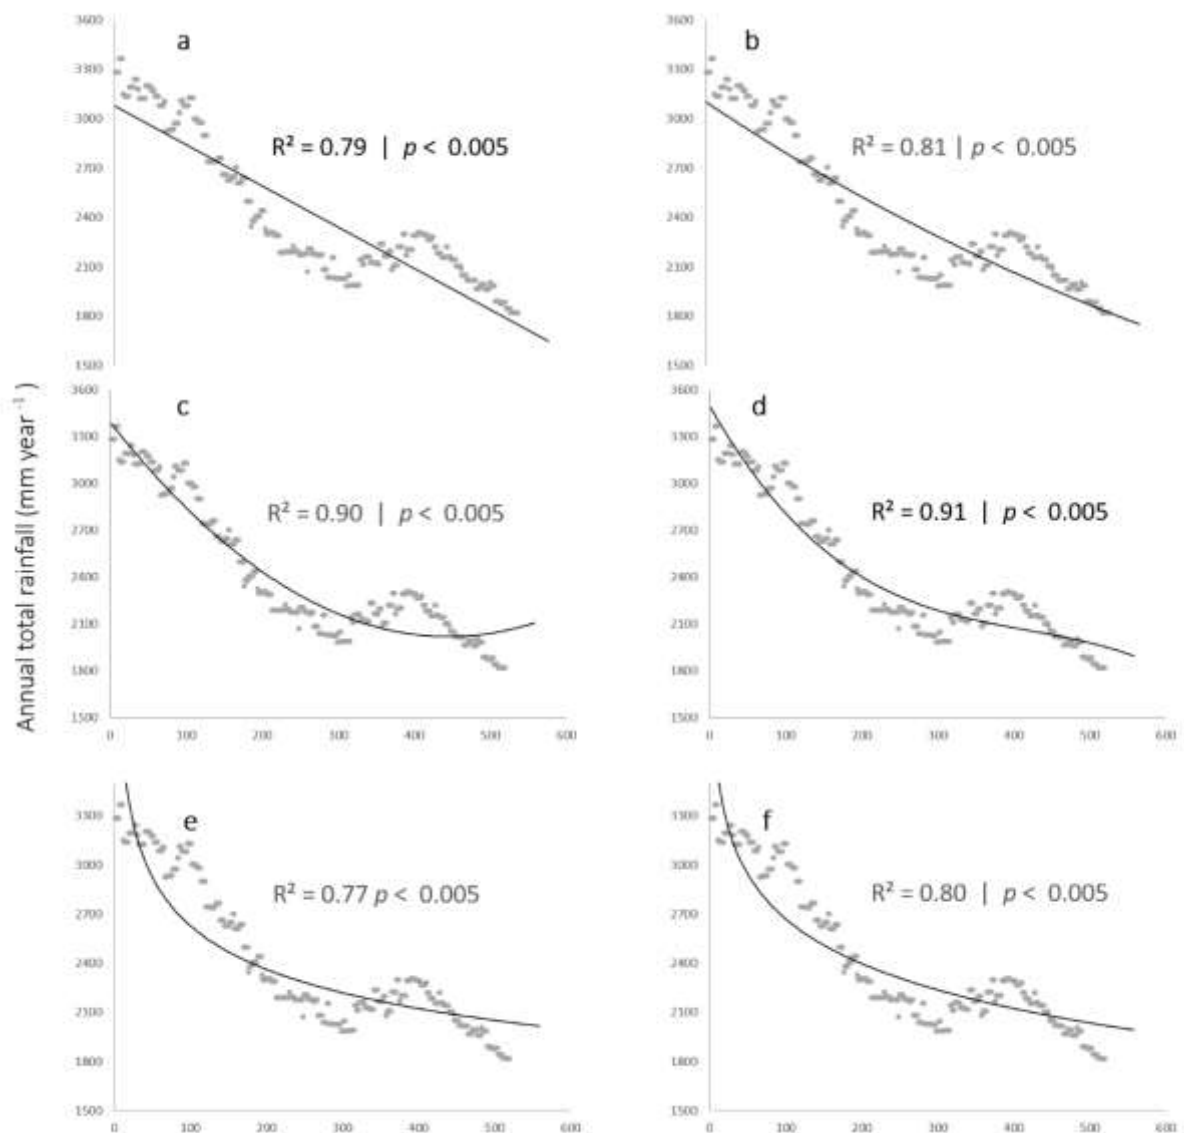
4.4.1 Modelling the spatial variability of annual rainfall

The TRMM data show a swath of high values of annual rainfall extending from NW to SE (Supplementary Figure 4.1), which may relate to the South Atlantic Convergence Zone (SACZ).



Supplementary Figure 4.1: Mean observed annual rainfall in southern Brazilian Amazon. Beige to blue gradient colour indicates the total annual rainfall (mm year⁻¹) from the Tropical Rainfall Measuring Mission between 1999 and 2019.

We computed a rainfall profile along a transect from NW to SE to evaluate this gradient by testing different non-linear regression models to select the one that provides a good fit to the data (Supplementary Figure 4.2). Although the third-degree polynomial model yielded a slightly higher fitting, the gains are not so expressive when compared with the results of a second-degree polynomial model. To avoid overfitting common to high degree polynomial models, we opted for the second-degree polynomial model.



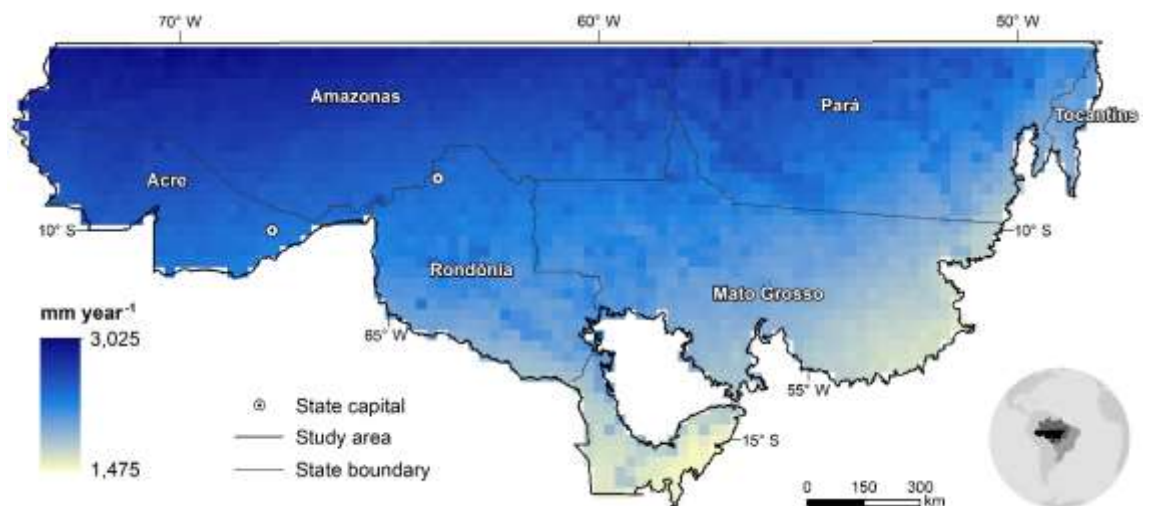
Supplementary Figure 4.2: Regression models fitted to TRMM rainfall data along transect from NW to SE across Southern Brazilian Amazon. a Linear model. b Exponential model, c Second-degree polynomial model. d Third-degree polynomial model. e Potential model and f Logarithmic model. All regressions are statistically significant with $p < 0.005$.

We also applied these non-linear regression models to all cells of the study region and analysed the distance between known data points and the ones predicted with the regression models (the residual standard error).

Supplementary Table 4.1: Regression models fitted to TRMM rainfall data in Southern Brazilian Amazon.

Model	R ²	p-value	Residual standard error
Third-degree polynomial	0.75	< 0.005	193.6 mm
Second-degree polynomial	0.72	< 0.005	204.6 mm
Logarithmic	0.67	< 0.005	222.9 mm
Exponential	0.67	< 0.005	223.5 mm
Linear	0.66	< 0.005	226.2 mm
Potential	0.65	< 0.005	228.1 mm

Supplementary Figure 4.3 shows the mean annual rainfall estimates (1999 to 2019) calculated by using a second-degree polynomial model. Note that the map clearly depicts the signal of the SACZ with a good agreement with the observed values ($r^2 = 0.72$; $p < 0.005$). Table S2 shows the model residues and Table S3 shows the *summary* statistics for the second-degree polynomial model.



Supplementary Figure 4.3: Mean annual rainfall estimates for the southern Brazilian Amazon. Beige to blue gradient color indicates the total annual rainfall (mm year⁻¹) calculated by using a second-degree polynomial model. Note that the map clearly shows the signal of the South Atlantic Convergence Zone.

Supplementary Table 4.5: Residues from the second-degree polynomial model

Min	1Q	Median	3Q	Max
-842.32	-148.09	2.44	160.97	671.94

Supplementary Table 4.6: Coefficients of the second-degree polynomial model

	Estimate	Standard Error	t value	Pr(> t)
Intercept	-5.29x10 ³	4.92 x10 ²	-10.74	< 0.001
latitude	2.30x10 ²	1.37x10 ¹	16.74	< 0.001
atitude ²	4.69	6.68E-01	7.019	< 0.001
longitude	-2.71x10 ²	1.61x10 ¹	-16.813	< 0.001
longitude ²	-1.99	1.31x10 ⁻¹	-15.221	< 0.001
altitude	1.41	1.89 x10 ⁻¹	7.442	< 0.001
altitude ²	-1.02x10 ⁻³	3.15 x10 ⁻⁴	-3.247	< 0.001

We tested the assumption that these coefficients are constant over time by randomizing the annual data of the TRMM. We then calculated a correlation coefficient, i.e. Spearman Rank-Order Correlation Coefficients, between predicted values for the entire period of study and predicted values for three different time-periods. We concluded that, although there are small differences between the equations' coefficients, the results from the equation for the entire period of analysis strongly correlates (DANCEY; REIDY, 2004) with the ones for the three-separate time-periods. As a result, we find that Interannual changes in the spatial patterns are non-monotonic (as would be expected due to e.g. ENSO), and as such, should not bias our estimated effects.

Supplementary Table 4.7: Spearman Rank-Order correlation coefficients between rainfall values predicted for the entire time-period of study and those predicted using equations derived for three specific time-periods.

Period	Spearman's rho	Interpretation
1999 to 2006	0.58	Strong relationship
2007 to 2013	0.75	Very Strong relationship
2014 to 2019	0.56	Strong relationship

4.4.2 Detrending procedure

To minimize omitted variable bias in our regression analysis, we firstly removed the effects of factors other than deforestation that may affect rainfall across both time and space. To remove the trends associated with geographic location and elevation, as well as part of the interannual variability associated with large-scale climate mechanisms, hence isolating the deforestation effects from those of natural variability, we calculated anomalies of annual rainfall ($P'_{i,j,t}$) using a 3-step procedure, summarized in Supplementary Equations 4.1, 4.2 and 4.3 and Supplementary Figure 4.4. Notations are as follows:

i, j, t = subscripts representing space (i, j) and time (t) dimensions.

$P_{i,j,t}$ = annual rainfall values in mm year⁻¹.

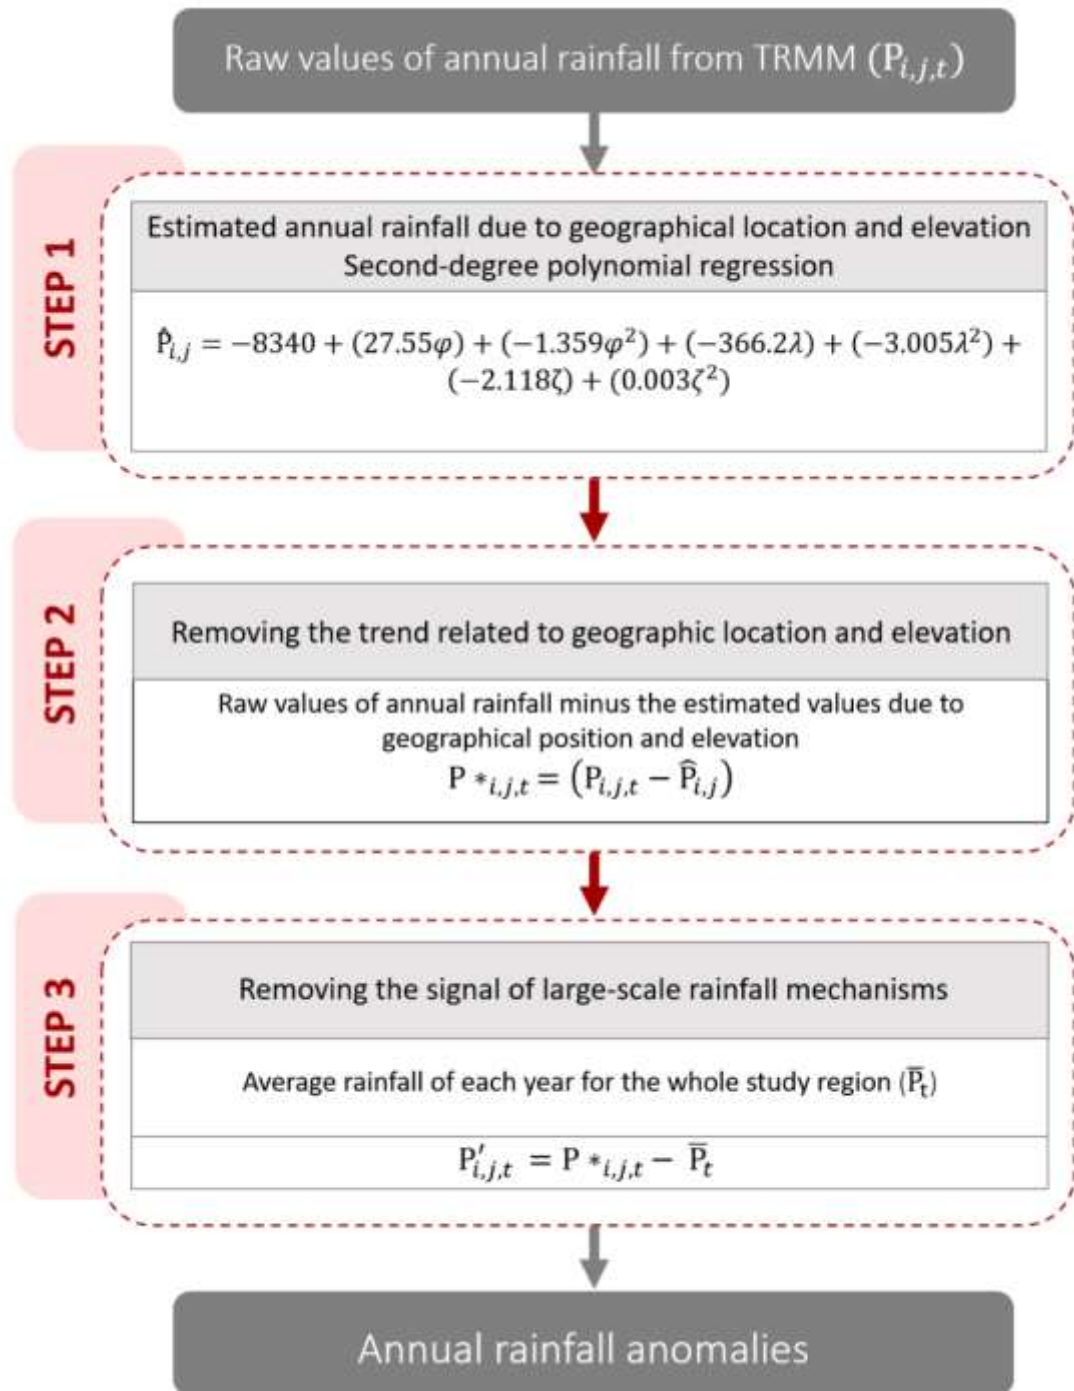
$\hat{P}_{i,j}$ = estimated values of rainfall due to geographical location and elevation.

$P *_{i,j,t}$ = difference between observed annual rainfall values and the estimated ones due to geographical location and elevation.

\bar{P}_t = annual averages of rainfall calculated throughout the study region.

$P'_{i,j,t}$ = residual annual rainfall anomalies in mm year⁻¹.

φ, λ, ζ = latitude, longitude (in *degrees*), and elevation (m), latitudes south of the Equator receive negative values, and longitudes west of the Greenwich Meridian receive negative values.



Supplementary Figure 4.4: 3-step procedure to calculate the anomalies. Diagram with method steps to calculate the annual rainfall anomaly for each grid cell. i, j, t are the subscripts representing space (i, j) and time (t) dimensions, $P_{i,j,t}$ are the annual rainfall values in mm, $\hat{P}_{i,j}$ are the estimated values of rainfall due to geographical location and elevation; $P^*_{i,j,t}$ is the difference between observed annual rainfall values and the estimated ones due to geographical location and elevation; \bar{P}_t are the annual averages of rainfall calculated throughout the study region; $P'_{i,j,t}$ are the residual annual rainfall anomalies; φ, λ, ζ are the subscripts representing latitude, longitude (in degrees), and elevation (in meters).

Step 1:

As aforementioned, the spatial pattern of annual rainfall depicts a swath of high values extending from NW to SE that may be associated with the South Atlantic Convergence Zone. This swath of high rainfall values traverses our study region. To remove this large-scale geographical pattern, we used increasingly complex regression models on latitude, longitude and elevation calculated using the climatological averages from 1999 to 2019. We found that a second-degree polynomial model on latitude, longitude and elevation is sufficient to describe this geographical climatological pattern (equation (S4.1); $r^2 = 0.72$; $p > 10^{-5}$). Using this model, we computed estimated values of rainfall due to this geographical pattern so that:

$$\hat{P}_{i,j} = -8340 + (27.55\varphi) + (-1.359\varphi^2) + (-366.2\lambda) + (-3.005\lambda^2) + (-2.118\zeta) + (0.003\zeta^2) \quad (\text{S4.1})$$

Step 2:

Next, we spatially detrended the values of annual rainfall (i.e., to remove the climatological trend related to geographic location and elevation). To do this, we calculated the difference between raw values of observed rainfall in each year and the estimated values due to geographical position obtained from equation (S1), so that.

$$P^*_{i,j,t} = (P_{i,j,t} - \hat{P}_{i,j}) \quad (\text{S4.2})$$

Since the coefficients of equation (S4.1) are static over time, the results from equation (S4.2) represent the observed deviation (anomaly) from the climatological pattern due to the interannual variability.

Large-scale interannual climate phenomena may also affect the annual averages of rainfall values. El Niño Southern Oscillation (ENSO) is the most important interannual variability modulating rainfall in the region, which indeed shows a high correlation with rainfall in our study region (Supplementary Figure 4.6). Since our time-series is relatively short, there is a bias (albeit weak) toward higher Nino 3.4 indexes, possibly associated with a partial cycle of the Pacific Decadal Oscillation (PDO). As forest losses across the study region increase monotonically as a function of time, Nino 3.4 trend coinciding with forest loss may bias the analysis.

Step 3:

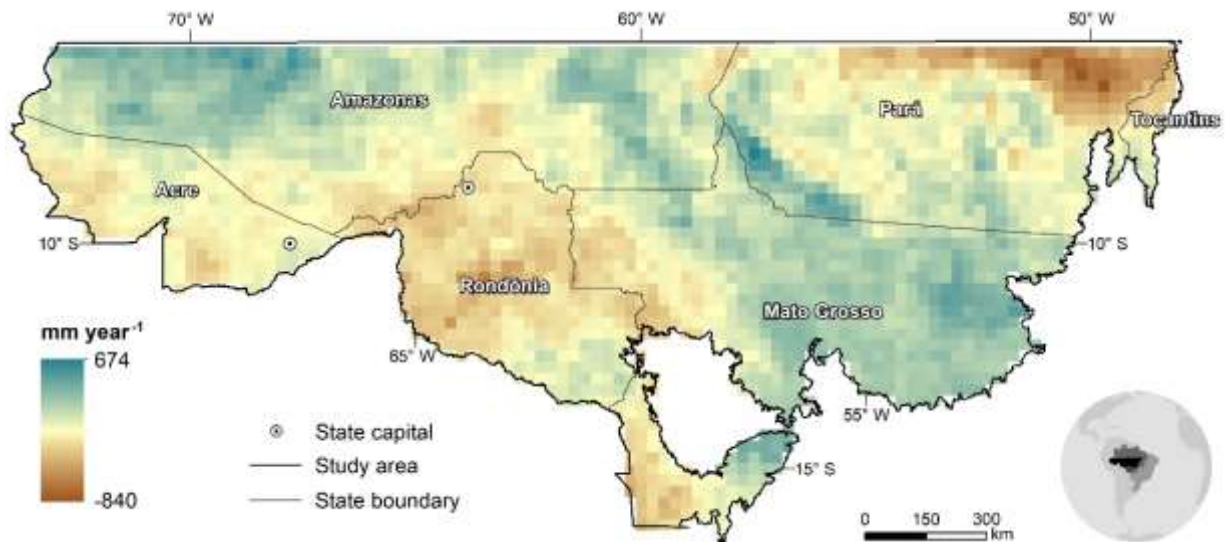
To remove the signal of large-scale factors, such as that of the ENSO, we subtracted the mean annual rainfall for the whole study region from the outputs of equation (S4.2):

$$P'_{i,j,t} = P_{i,j,t} - \bar{P}_t \quad (\text{S4.3})$$

The residual is assumed to be an ‘anomaly’ that is not explained by the geographic location, elevation or large-scale time-varying factors.

4.4.3 Verification of the detrending method

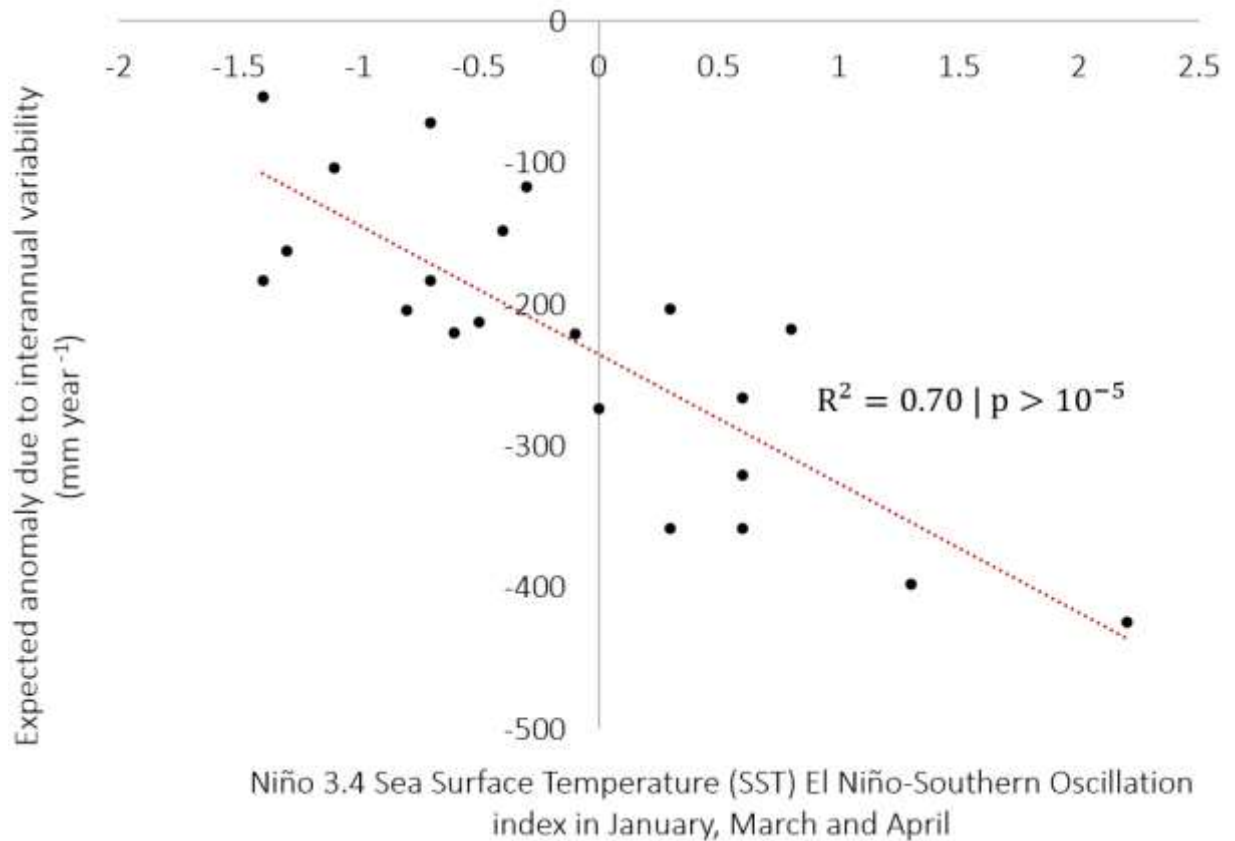
To show that the detrending method works, we present a map of difference (residues) between raw values of observed annual rainfall and the estimated values due to geographical location and elevation (Supplementary Figure 4.5). In general, the difference is between 120 mm and -120 mm, i.e., less than 10% of the annual rainfall.



Supplementary Figure 4.5: Residues between raw values of observed annual rainfall and the estimated values due to geographical location and elevation. Brown to blue gradient color indicates residues between raw values of observed annual rainfall from the Tropical Rainfall Measuring Mission data and the estimated values after equation (S4.1).

As mentioned earlier, we attempted to remove the spatial patterns that might be correlated with deforestation and would thus lead to bias in our regression analyses. We added the step 3 in which we subtracted the annual regional average rainfall from equation (4.2) to control for possible large-scale

mechanisms that affect, on annually basis, the region as whole. This average is highly correlated with the Niño 3.4 Sea Surface Temperature (SST) ENSO index from the US National Oceanic and Atmospheric Administration in January, February and March (JFM - The rainiest months in the Amazon; Supplementary Figure 4.6).



Supplementary Figure 4.6: Mean annual rainfall anomalies and the best-fit linear regression with ENSO. Mean annual rainfall anomalies between 1999 and 2019 and the best-fit linear regression (red dashed line) with El Niño Southern Oscillation (ENSO) indexes in the Niño 3.4 region.

After this step, the residual is assumed to be a “rainfall anomaly” that is not explained by the geographic location, elevation and the interannual variability. As expected, after this procedure, the annual means situate around zero (Supplementary Table 4.4).

Supplementary Table 4.4: Mean annual anomalies for study region between 1999 and 2019.

Year	Mean anomaly
1999	-6.1×10^{-13}
2000	1.12×10^{-13}
2001	-1.3×10^{-13}
2002	1.61×10^{-14}
2003	-7.2×10^{-13}
2004	-2×10^{-13}
2005	-3.2×10^{-13}
2006	-3.4×10^{-13}
2007	8.9×10^{-14}
2008	-2.8×10^{-14}
2009	-1.1×10^{-13}
2010	9.97×10^{-13}
2011	8.85×10^{-14}
2012	$-9.6E \times 10^{-14}$
2013	1.01×10^{-13}
2014	-3.1×10^{-13}
2015	4.39×10^{-13}
2016	-1.1×10^{-13}
2017	-3.3×10^{-14}
2018	8.97×10^{-14}
2019	-1.9×10^{-13}

4.4.4 Separating the effects of forest loss from the mean long-term trend in rainfall

Since historical advance of the deforestation frontier (from south to north and east to west) could have possibly coincided with climate trends, we separated the effects of forest loss from the mean long-term trend in rainfall by performing a t-test. The t-test compares the annual rainfall between cells with smaller forest loss and cells that experienced larger forest loss within two separated periods: 1999–2009 and 2010–2019.

Supplementary Table 4.5: Cell grid groups divided by forest loss fraction for the periods 1980–1996 and 1997–2012.

	Latitude	Longitude	elevation	deforestation (%)	
1	-8.1034	-54.2299	178	25.1	1999–2009
				27.3	2010–2019
2	-9.0378	-55.9949	191	24.9	1999–2009
				57.2	2010–2019

Results demonstrate that the cells with smaller forest loss over the periods (not reaching 55-60% forest losses) have an annual rainfall increase of $+96.9 \pm 12.65$ mm, whereas cells with larger forest losses (exceeding 55-60% forest loss) have an annual decrease of -306.4 ± 42.77 mm. Both relations are significant at $p = 10^{-5}$.

Supplementary Table 4.6: Two-Sample t-test with unequal sample sizes and unequal variance of means of annual rainfall anomalies ($P_{i,j,t}$) for cell groups 1 and 2 for the 1999–2009 and 2010–2019 periods.

Group	μ		S^2		t_{calc}	$P_{1\text{-tailed}}$
	1999–2009	2010–2019	1999–2009	2010–2019		
1	1998.4 mm	2095.3 mm	120.12 mm	131.35 mm	0.252	0.249
2	2079.3 mm	1772.9 mm	129.11 mm	170.56 mm	-1.983	0.012

4.4.5 Environmental governance scenarios

4.4.5.1 The weak environmental governance (WEG) scenario

The weak environmental governance scenario assumes the abandonment of current deforestation control policies, as well as strong political support for predatory agricultural practices. In practice, the environmental achievements attained in the Amazon since 2005 would be completed undone by 2025. This represents the worst-case scenario and should be viewed as a complete deconstruction of environmental governance in Brazil with severe impacts on deforestation rates, which could potentially return to pre-2005 levels. As a result, annual deforestation rates would reach 27,000 km² by 2025.

4.4.5.2 The strong environmental governance (SEG) scenario

The strong environmental governance (SEG) scenario assumes the expansion of current deforestation command-and-control policies under full political support for the country's environmental agenda, including the through implementation of the Forest Code alongside economic incentives for forest conservation. Annual deforestation in the Amazon would be reduced from 7,989 and 9,483 km² in 2016 and 2015, respectively, to 4,000 km² by 2030.

4.4.6 Effects of deforestation on agricultural production and economic analysis

The economic analysis is based on simulations of deforestation under a weak (WEG) and strong (SEG) environmental governance scenario (ROCHEDO *et al.*, 2018) described earlier. These associated economic losses are estimated using an origin-destination rainfall relationship at a broader scale (STRAND *et al.*, 2018). These analyses complement the manuscript aimed at illustrating how important deforestation-rainfall effects can be to the region's economy.

4.4.7 How a reference yield is modified as the local climate changes due to incremental forest loss

Strand *et al.* (STRAND *et al.*, 2018) ran computer simulations using the Integrated Model of Land Surface Processes (INLAND) (PIRES *et al.*, 2016) to calculate how a reference yield is modified as the local climate changes due to incremental forest loss. The soybean yield and pasture productivity calculated using the INLAND model is a function of a set of climate variables, crop and soil parameters. Strand *et al.* used the climate variables output by the Community Climate Model version 3, coupled to the Integrated Biosphere Simulator version 2.6.4 (named CCM3-IBIS) for modelling the impact of incremental deforestation scenarios on rainfall regulation. In these simulations, Strand *et al.* used the climate variables output from the climate model for each deforestation scenario F_x , where x is the percentage of total Amazon Forest loss. The 10% Amazon deforestation scenario (F_{10}) is the baseline for calculations of relative differences, as follows:

4.4.7.1 Change in revenue per hectare for Soybeans:

The change in soybean yield in each deforestation scenario is denoted below:

$$\Delta Y_{i,j}^d = (Y_{i,j}^{F_x} - Y_{i,j}^{F_{10}}) \text{ if } d = F_x, x = 10, 20, \dots, 40. \quad (S4)$$

where i and j refer to latitude and longitude, respectively; $\Delta Y_{i,j}^d$ is the change in soybean yield in cell i,j for a deforestation scenario d (ton ha⁻¹); $Y_{i,j}^{F_x}$ is the soybean yield (ton ha⁻¹) in cell i,j in one of the deforestation scenarios F_x ($x = 10, 20, \dots, 40\%$ of Amazon deforestation); $Y_{i,j}^{F_{10}}$ is the soybean yield in cell i,j in the standard scenario F_{10} (ton ha⁻¹); and A^{F_x} is the total area deforested in scenario F_x (km²). If the deforestation scenario d is different than one of the

standard scenarios Fx ($x = 10, 20, \dots, 40\%$ of Amazon deforestation), then the result is interpolated using equation (S4.5):

$$\Delta Y_{i,j}^d = \sum_{x=20}^{40} (Y_{i,j}^{Fx} - Y_{i,j}^{F10}) \cdot \left(\frac{A^{Fx}}{A^{F10}} \right) \quad (S4.5)$$

The percentage change $\Delta Y_{ij} \%$ in soybean yield is as follows:

$$\Delta Y_{ij} \% = \frac{\Delta Y_{i,j}^d}{Y_{i,j}^{F10}} \cdot 100 \quad (S4.6)$$

Change in revenue per hectare is calculated by multiplying the simulated yield and the price of a ton of soybean:

$$\Delta R_{ij}^{ha} = \frac{\Delta Y_{ij} \%}{100} \cdot Y_{i,j}^{ref} \cdot P_{soy} \quad (S4.7)$$

Where ΔR_{ij}^{ha} is the change in soybean revenue per hectare in cell i,j (US\$ ha⁻¹) and P_{soy} is the price of a ton of soybean (US\$ ton⁻¹).

4.4.7.2 Change in revenue per hectare for cattle beef

The cattle beef production is derived using the regional stocking rates as of 2012:

$$C_{ij}^{ref} = \frac{S_{ij}^{ref} \cdot W \cdot r}{a \cdot t_s} \quad (S4.8)$$

where C_{ij}^{ref} is the reference cattle beef production (arroba/ha/year). S_{ij}^{ref} is the reference stocking rate as of 2012 (heads ha⁻¹); W is the national average weight per animal (540 kg head⁻¹); r is the average ratio dead weight/live weight ($r = 0.41$); a is the conversion factor from arroba to kg ($a = 15\text{kg arroba}^{-1}$); and t_s is the average animal age at slaughter ($t_s = 2$ years).

Change in pasture productivity P in each deforestation scenario is calculated using equations (S4.9) and (S4.10):

$$\Delta P_{i,j}^d = (P_{i,j}^{Fx} - P_{i,j}^{F10}) \quad \text{if } d = Fx, x = 10, 20, \dots, 40. \quad (S4.9)$$

where i and j refer to latitude and longitude, respectively; ΔP is the change in pasture productivity (ton/ha) in cell i,j in one of the deforestation scenarios Fx ($x = 10, 20, \dots, 40\%$ of Amazon deforestation) d ; P is the pasture productivity (Kg-C.m⁻².yr⁻¹ ha⁻¹) in cell i,j in one of

the deforestation scenarios F_x ($x = 10, 20, \dots, 40\%$ of Amazon deforestation); $P_{i,j}^{F10}$ is the pasture productivity in pixel i,j in the standard scenario F_{10} (ton ha⁻¹); and A^{F_x} is the total area deforested in scenario F_x (km²). If the generic deforestation scenario d is different than one of the standard scenarios F_x ($x = 10, 20, \dots, 40$), then the result is interpolated using equation (S4.10):

$$\Delta P_{i,j}^d = \sum_{x=20}^{40} (P_{i,j}^{F_x} - P_{i,j}^{F10}) \cdot \left(\frac{A_d^{F_x}}{A^{F_x}} \right) \quad (\text{S4.10})$$

The percentage change $\Delta P_{ij} \%$ in pasture productivity is denoted as follows:

$$\Delta P_{ij} \% = \frac{\Delta P_{i,j}^d}{P_{i,j}^{F10}} \cdot 100 \quad (\text{S4.11})$$

Equation (S4.12) then calculates the change in cattle beef production:

$$C_{ij}^d = \frac{C_{ij}^{\text{ref}} \cdot \Delta P_{ij} \%}{100} \quad (\text{S4.12})$$

The revenue per hectare is calculated by multiplying the cattle beef production per hectare per year and the price of the arroba:

$$E_{ij}^{ha} = C_{i,j}^d \cdot P_{\text{arroba}} \quad (\text{S4.13})$$

where E_{ij}^{ha} is the cattle beef revenue per hectare per year in cell i,j (US\$ ha⁻¹ yr⁻¹) and P_{arroba} is the price of an arroba of dead weight (US\$ arroba⁻¹).

Next, we projected productivity change until 2050 from estimates of soybean and pasture productivity losses due to lower rainfall caused by Amazon region-wide deforestation under WEG and SEG scenarios. To do so, we adjusted soybean productivity projections (3.7 ton hectare⁻¹; MINISTÉRIO DA AGRICULTURA, 2019) and pasture productivity projections (2.9 arroba hectare⁻¹; BATISTA *et al.*, 2019) by the average productivity losses. We computed annual revenues in US\$ per hectare using current soybean and cattle arroba prices (US\$ 302.58 per ton and US\$ 201.50 per arroba, respectively) and projected soybean and pasture productivity for each of the two forest loss scenarios (WEG and SEG) with and without decreases in yields. Under WEG and SEG scenarios, total annual revenues are calculated by weighting soy and pasture revenues using the simulated future croplands and pasturelands.

Next, we calculate the Net Present Value (NPV; Eq. S4.14) of future revenues for the Southern Amazon using as discount rate the Special System of Clearance and Custody rate (Selic interest rate) of 3.75% (the Selic interest rate is determined by Brazil's Central Bank).

$$NPV = \frac{R_t}{(1+i)^t} \quad (S4.14)$$

Where t is the time of the cash flow, i is the Selic interest rate and R_t is the net cash flow i.e. cash inflow – cash outflow, at time t . We computed the difference between the total NPV of revenues under the WEG versus the SEG scenario is the opportunity cost of the SEG scenario.

Finally, we converted NPV into Equivalent Annual Annuity (EAA; Eq. 4.15).

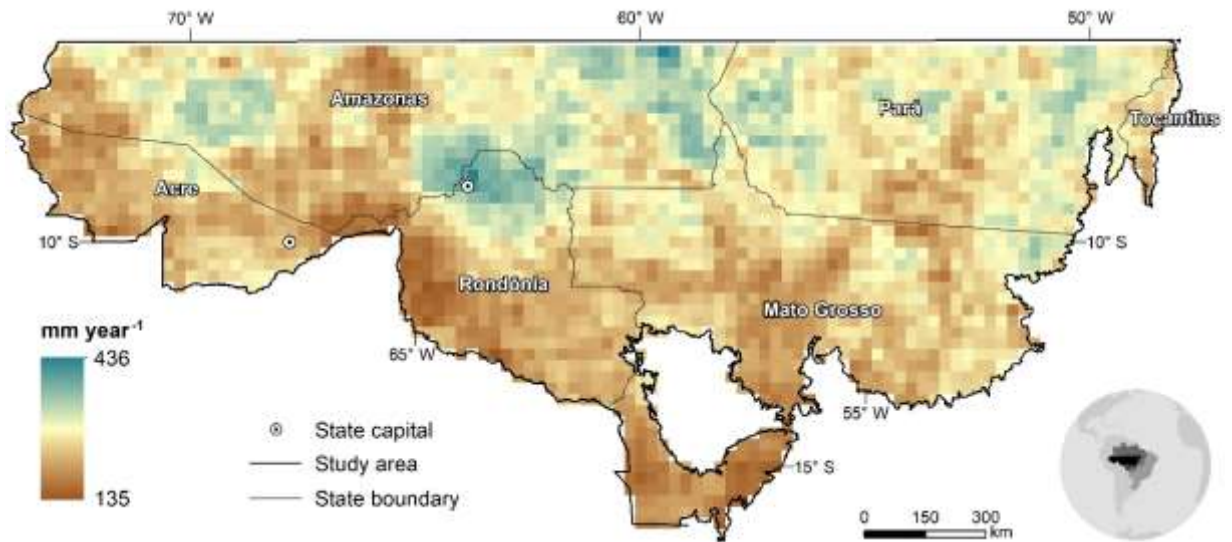
$$EAA = \frac{i \times NPV}{1 - (1+i)^{-N}} \quad (S4.15)$$

where i is the Selic discount rate, NPV is the net present value calculate trough equation (S4.14) and N is the simulation period (i.e., the planning horizon, in years). Similarly, the difference between total EAA of revenues under the WEG versus the SEG scenario is the annually opportunity cost of the SEG scenario.

4.5 SUPPLEMENTARY RESULTS AND DISCUSSION

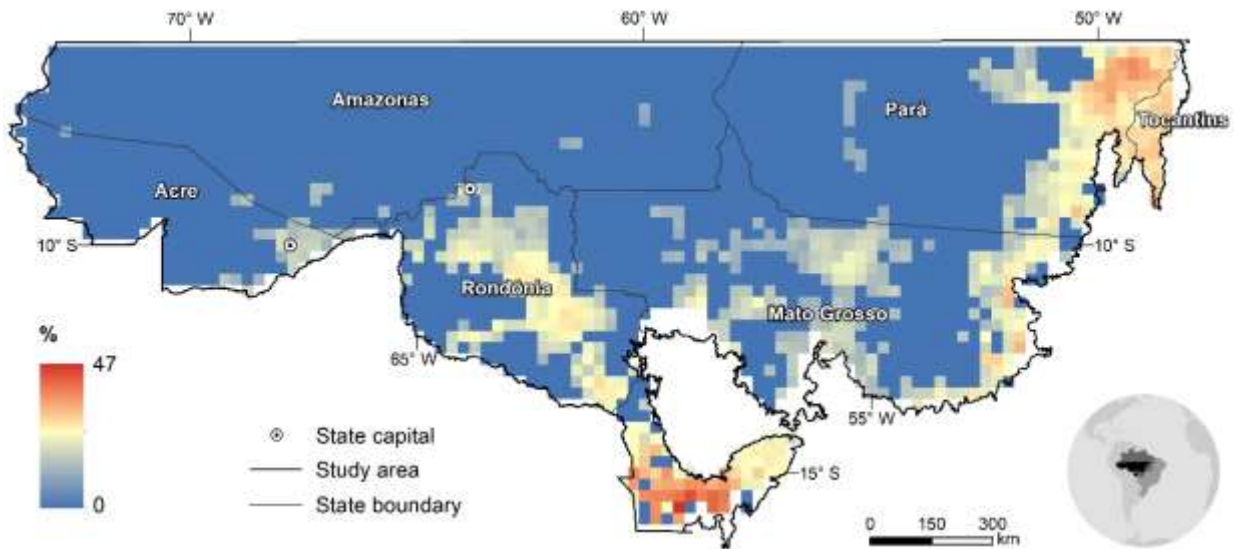
4.5.1 How relevant these rainfall reductions are in magnitude

Our estimates of 2096 mm year⁻¹ for the study region using the TRMM database have a standard deviation (σ) of 245.2 mm year⁻¹ ($\approx 11\%$). Considering our results (-4.9 mm of rainfall reduction per each 1% increase in forest loss), in a hypothetical case of 80% of forest loss (in a 28-km cell), the tantamount reduction would be of $\approx 19\%$, thus 8% larger than the typical year-to-year variability. However, it is important to stress that these inferences are for the study region as a whole. Particular regions may be more or less affected according to their locations. As presented earlier, there is a striking spatial variability in the standard deviation of annual rainfall (Supplementary Figure 4.7).

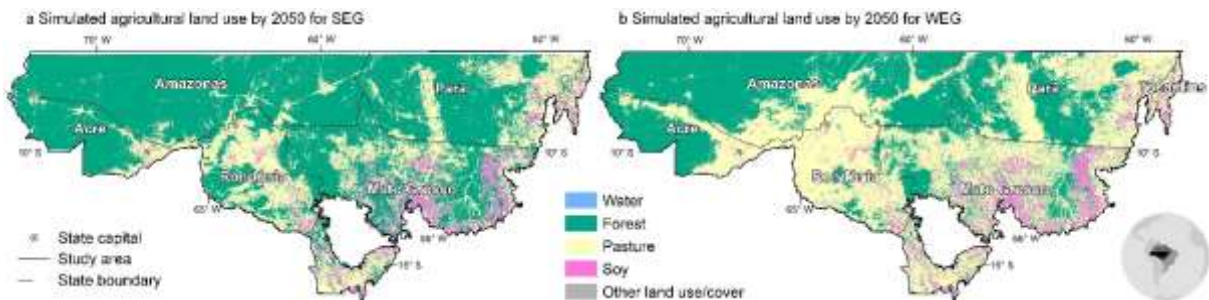


Supplementary Figure 4.7: Standard deviation of annual rainfall. Brown to blue gradient color indicates standard deviation of annual rainfall within each 28x28-km grid cell in the period of 1999 to 2019.

The smallest interannual variability is verified in grid cells that are located in south and southwest of the Amazon, in the same regions where the annual rainfall is lower; consequently, in those regions rainfall reduction due to deforestation is proportionally larger. For example, in some regions rainfall reduction by 2019 may have already reached 48% of the annual rainfall (Supplementary Figure 4.8). This has a large implication for agriculture since those areas mostly affected by rainfall reduction are the ones where soy croplands concentrate or are likely to expand by 2050 (Supplementary Figure 4.9).



Supplementary Figure 4.8: Estimated rainfall reduction by 2019 due to forest loss in grid cells that have crossed the critical threshold of forest loss.



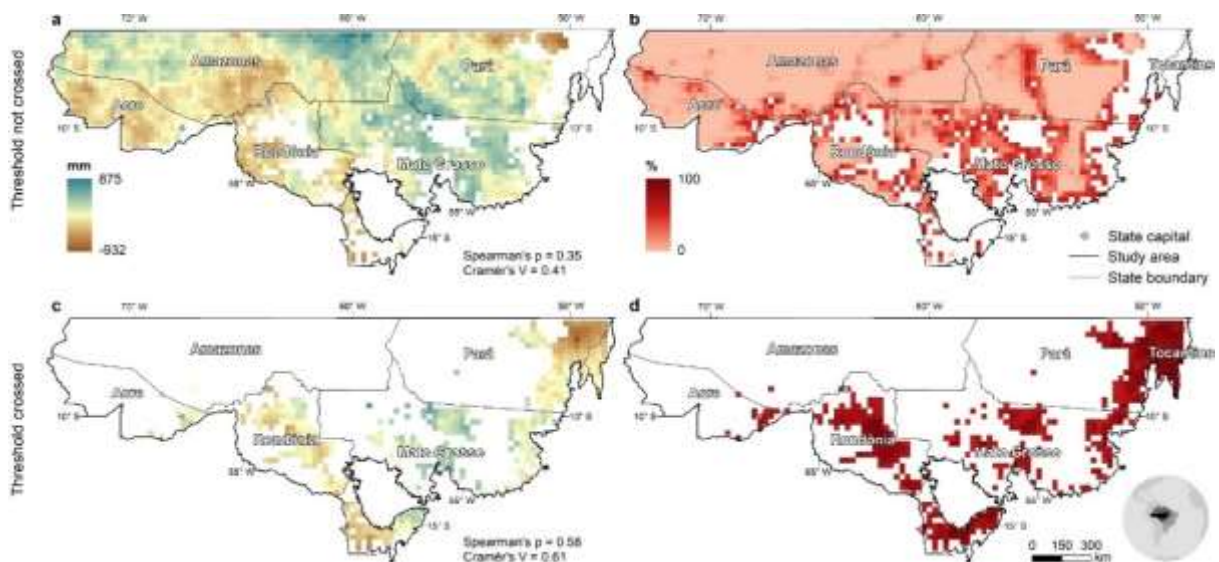
Supplementary Figure 4.9: Simulated agricultural land use by 2050. Simulated agricultural land use by 2050 for a SEG, b and WEG. Deforested area (yellow) by 2019 according to Program to Calculate Deforestation in the Amazon (PRODES).

The fact that the reduction in rainfall could be smaller than the typical year-to-year variability in some of the grid cells does not mean that there is no impact on agricultural production. Since we have isolated the signal of deforestation, the effect of deforestation on rainfall is additional to the interannual variability, further increasing risks of crop failure especially in dry or drought years. Furthermore, crop yields and the adoption of double cropping systems vary significantly from year to year in the region, partially because of the interannual climate variability (COHN *et al.*, 2016; ABRAHÃO; COSTA, 2018). Therefore, it is reasonable

to assume that even changes that are smaller than the interannual variability may be relevant to agriculture in the region.

4.5.2 Evidence for forest loss causation of rainfall reduction

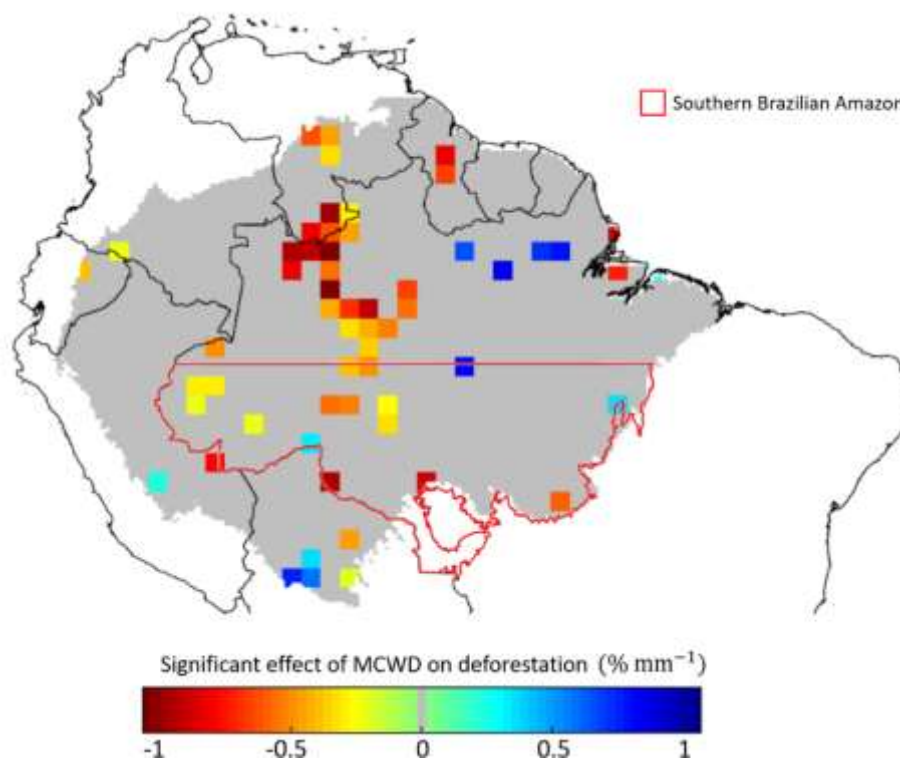
We also evaluated the spatial variability in anomalies calculating the Cramer's V (CRAMÉR, 1946) and the Spearman Rank Order Correlation coefficient (SPEARMAN, 1904) to measure the spatial association between forest loss and estimated anomalies for cells that have reached the critical threshold of forest loss and cells that have not crossed this limit. As expected, after isolating the deforestation effects, anomalies exhibit a spatial variability correlated only with forest loss (Supplementary Figure 4.10), thus an additional evidence for forest loss causation of rainfall reduction.



Supplementary Figure 4.10: Spatial association between forest loss and estimated anomalies for 2019. Spatial variability in anomalies and the Cramer's V (CRAMÉR, 1946) and the Spearman Rank Order Correlation coefficient to measure the spatial association between forest loss and estimated anomalies for **c** and **d** cells that have reached the critical threshold of forest loss and **a** and **b** cells that have not crossed this limit. Brown to blue gradient color indicates precipitation anomalies (mm) for 2019. Red to pink gradient color indicates forest loss (%) within 28 km grid cells. Each point represents the location of a State Capital.

The relation between forest loss and rainfall presented here is correlational. Recently study point out to that forest loss causes 4% of droughts, while droughts account for 0.13% of forest loss per millimetre of rainfall reduced in the Amazon biome (STAAL *et al.*, 2020). To investigate the possible influence of a drier climate on deforestation in SAB, we superimposed data of Staal *et al.* (STAAL *et al.*, 2020) on the map of our study region. We found that only 12

cells of a total ≈ 86 non-null cells (14% of our study region) show a statistically significant effect that more severe forest loss tends to take place in drier (or drying) parts (Supplementary Figure 4.11); Figure was created using data from STAAL *et al.*, 2020 (STAAL *et al.*, 2020)). We also found for the few cells that have statistical significance ($\alpha = 0.05$) that this effect is $\approx 0.09 \text{ \% yr}^{-1} \text{ mm}^{-1}$ in our study region, i.e. near zero. In other words, only in these few areas forest loss may significantly increase (though very little according to the authors' own results) as climate becomes drier. Furthermore, the same authors point out that forest loss has intensified dry seasons especially in the southwestern Amazon (our study region), stressing that the causality of forest loss on rainfall in our study region is more important than the other way around. Additionally, empirical evidence that the length of the rainy season decreases $\approx 0.9 \pm 0.34$ day per each 10% of forest loss has been published recently (LEITE-FILHO; COSTA; RONG, 2019).



Supplementary Figure 4.11: Significant effect of Maximum cumulative water deficit on deforestation. One degree grid cells with a significant ($\alpha = 0.05$) temporal effect of the Maximum Climatological Water Deficit on deforestation (MCWD; $\text{\% yr}^{-1} \text{ mm}^{-1}$). Colours indicate change in deforestation for each mm reduction in MCWD as a percentage of the average annual local forest suppression. Note that cells with statically significant effect concentrate in the highly humid forests of Northwestern Amazon.

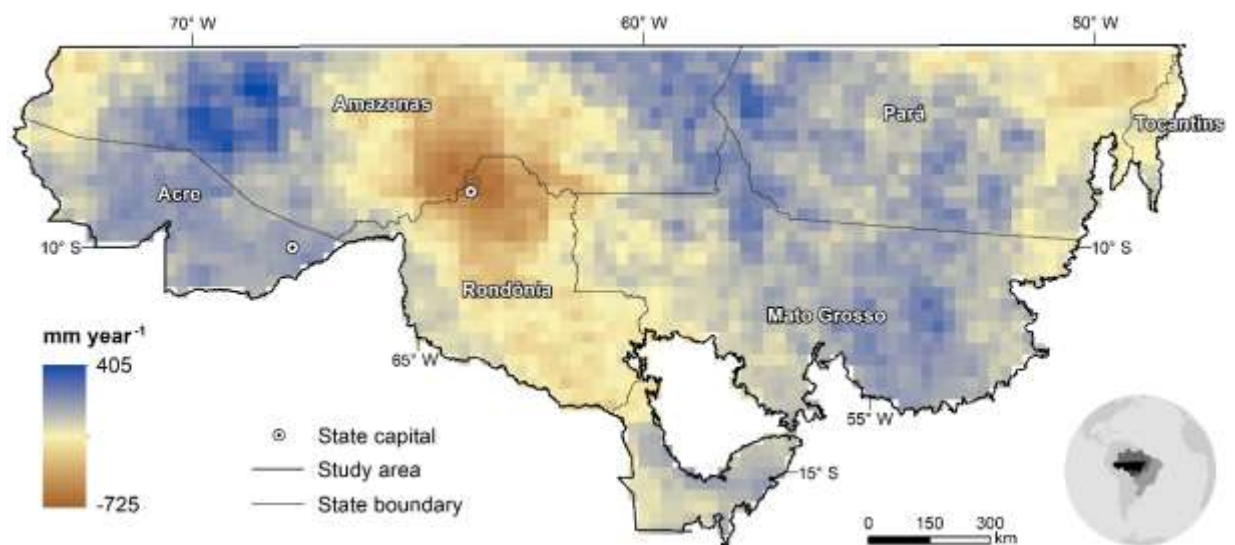
4.5.3 Spatially-explicit signal of the reduction of rainfall in the region

We tested whether the mean annual rainfall in Southern Amazon is different between two periods: 1999-2009 and 2010-2019, using Two-Sample t-test. Results are significant at 5% level of significance (Supplementary Table 4.7: Two-Sample t test with equal sample sizes and unequal variance of annual rainfall means for the 1999–2009 and 2010–2019 periods)

Supplementary Table 4.7: Two-Sample t test with equal sample sizes and unequal variance of annual rainfall means for the 1999–2009 and 2010–2019 periods


μ		S^2		t_{calc}	$P_{1\text{-tailed}}$
1999–2009	2010–2019	1999–2009	2010–2019		
2092.6 mm	1828.1 mm	113.22 mm	121.86 mm	0.162	0.213

As a result, Supplementary Figure 4.12 depicts a clear signal of rainfall reduction, mostly notable where deforestation concentrates in Rondônia and Eastern Amazon.



Supplementary Figure 4.12: Difference of mean annual rainfalls between two periods: 1999-2009 and 2010-2019.

4.6 SUPPLEMENTARY FIGURES



Supplementary Figure 4.13: Length of the dry season in Southern Amazon between 1980 and 2010 obtained from National Oceanic and Atmospheric Administration/US (NOAA) Climate Diagnostics Center (CDC) daily precipitation gridded data product, version SA24 data. Years are classified into Long dry season (LDS) and short dry season (SDS) using a 0.75σ threshold. Supplementary Figure 4.13 was created using data from (AGUDELO *et al.*, 2019)

5 CAPÍTULO 2

**O DESMATAMENTO AGRAVA O RISCO AGROCLIMÁTICO NO CERRADO E
NA AMAZÔNIA BRASILEIRA**

Artigo em revisão.

Resumo

Evidências sobre o impacto da perda florestal no clima se acumulam. Períodos secos e temperaturas mais elevadas já são mais frequentes, deixando o agronegócio mais vulnerável. Portanto, a gestão de riscos agroclimáticos torna-se cada vez mais fundamental e deve ganhar cada vez mais destaque no cotidiano do Agronegócio. Neste contexto, a devastação ambiental gera preocupação porque contribui com a emissão de Gases de Efeito estufa (GEE) que intensificam as mudanças climáticas globais ao mesmo tempo em que interferem no clima regional das principais áreas produtoras de grãos do Brasil. Neste sentido, para explorar empiricamente o risco de mudanças climáticas regionais durante a janela de cultivo da soja e do milho associadas ao desmatamento do Cerrado (CE) e Amazônia Brasileira (AM) estimamos as probabilidades de ocorrência (ou riscos) de mudanças na sazonalidade e volume das chuvas e nos padrões de temperatura máxima e mínima. Ao analisarmos dados de precipitação, temperatura e perda florestal ao longo das duas últimas décadas, demonstramos que as séries temporais de área desmatada acumulada são úteis na previsão das mudanças climáticas regionais em uma escala regional (28km x 28km), ao passo em que as mudanças ligadas ao desmatamento são úteis na previsão das variações na produtividade da soja e do milho plantados nestas regiões. Ao analisarmos o risco de ocorrência de mudanças climáticas em regiões com diferentes percentuais de área desmatada, identificamos riscos de atrasos no início da estação chuvosa e conseqüentemente no início da semeadura da soja, menor volume de chuvas e temperaturas mais elevadas à medida que o desmatamento avança. Em uma região da AM com desmatamento permitido por lei (<20% da Área desmatada), o risco médio de que o período chuvoso comece 1 a 2 semanas mais tarde em comparação à climatologia local, é em média, de apenas ≈6%, subindo para ≈28% em uma região com 80% de sua área desmatada. Em uma região do CE com ≈35% da sua área desmatada, o risco de diminuição de 15 a 30% do volume de chuvas na primeira safra é em média ≈15%, e o risco das temperaturas máximas aumentarem 1.5°C em relação à normal climatológica é em média ≈7%. Em um caso de desmatamento extremo de 80%, o risco de diminuição das chuvas na safra sobe para ≈22%, ao passo que o risco de temperaturas máximas 1°C a 1.5°C mais quentes sobe para ≈15%. Somadas às ameaças associadas às mudanças climáticas globais, elevam-se as regiões e anos nos quais os sistemas de dupla safra são cultivados sob baixo risco climático. Portanto, a preservação e o cumprimento do Código Florestal Brasileiro são de interesse direto para a gestão de riscos agroclimáticos e conseqüentemente para a sobrevivência do setor.

5.1 INTRODUÇÃO

O desmatamento da Amazônia (AM) e Cerrado (CE) intensifica significativas mudanças nas interações biosfera-atmosfera que reduzem a duração e o volume das chuvas (LEITE-FILHO; PONTES; COSTA, 2019a; LEITE-FILHO; COSTA; RONG, 2019b; LEITE-FILHO *et al.*, 2021) e aquecem o ar (GATTI *et al.*, 2021). Dessa forma, além de erodir um importante reservatório global de carbono (GATTI *et al.*, 2021) e causar restrições à entrada das commodities agrícolas brasileiras em mercados externos (RAJÃO *et al.*, 2020), estes efeitos refletem negativamente na capacidade de produção (LEITE-FILHO *et al.*, 2021; Rattis *et al.*, 2022).

A remoção da vegetação nativa do CE e da AM aumenta o albedo e reduz a radiação líquida, alterando a partição da radiação em fluxo de calor latente e sensível. Quando comparadas às áreas florestadas, as áreas desmatadas têm albedo $\approx 5\%$ mais alto (CULF; FISCH; HODNETT, 1995), menor capacidade de armazenamento de umidade no solo e fluxo de calor latente 30% menor (GASH *et al.*, 1996). A conversão de áreas naturais em cultivos agrícolas reduz ainda a rugosidade da superfície, o índice de área foliar e a profundidade das raízes. Estas modificações fazem com que seja necessário um transporte de umidade mais forte e uma convecção mais profunda para que se possa desencadear a chuva já que a menor rugosidade diminui a turbulência atmosférica e enfraquece os movimentos verticais de massas úmidas (KHANNA *et al.*, 2017). Ou seja, sem a floresta não há chuvas, e na falta de chuvas, sobram prejuízos. O Agronegócio brasileiro já está deixando de ganhar cerca de U\$S 5 bilhões por ano por conta da questão ambiental apenas na AM e se esforços não forem feitos para conter os danos, a expectativa é de piora no cenário (LEITE-FILHO *et al.*, 2021).

Mesmo diante deste conhecimento científico, a agropecuária provocou 97% da perda de vegetação nativa em 2021, principalmente na AM, que concentrou 59% da área desmatada, seguida pelo CE (30% da área desmatada; MAPBIOMAS, 2022). Toda esta devastação causa um risco agroclimático acentuado que ainda não foi plenamente quantificado. Em parte, devido à escassez da rede de monitoramento climático *in situ* ou pela falta de mapas de alta resolução que representam o desmatamento nestas regiões. Além disso, são raros os estudos que optam por uma abordagem probabilística capaz de quantificar a probabilidade de ocorrência de mudanças climáticas induzidas pelo desmatamento no Brasil com base em dados observacionais ao invés da aplicação de uma abordagem determinística.

Neste artigo utilizamos dados de sensoriamento remoto de precipitação, temperatura, uso da terra e produtividade agrícola para estimar os riscos de mudanças climáticas regionais (28km x 28km) sob diferentes níveis de desmatamento na AM e no CE durante as janelas de cultivo da primeira e segunda safras (soja e milho), que resultam em significativas alterações nas produtividades das lavouras. Assim, contribuímos para a mitigação ou adaptação aos riscos agroclimáticos aos quais as principais culturas agrícolas do Brasil estão submetidas. Dessa forma, visamos contribuir para o incremento da capacidade adaptativa da produção de grãos, incluindo o planejamento e ações voltadas para a estabilidade da renda dos produtores através da conservação florestal.

5.2 DADOS E MÉTODOS

5.2.1 Região de estudo

Nossa região de estudo abrange 80% do território brasileiro, englobando a integralidade dos Biomas AM e CE presentes no País. Mais de 40% (13,6 milhões de toneladas) das importações anuais de soja da União Europeia e Reino Unido são provenientes do Brasil e 69% desse total, da AM e do CE (RAJÃO *et al.*, 2020).

5.2.1.1 Amazônia

A AM brasileira ocupa 49% do território nacional e 60% de toda a extensão do Bioma. Nove estados brasileiros estão em parte ou integralmente incluídos neste bioma: toda extensão do Amazonas, de Roraima, do Acre e do Amapá; além de parte dos estados do Pará, Rondônia, Mato Grosso, Maranhão e Tocantins. Até a década de 70, apenas 1% das florestas na região haviam sido desmatadas (DIAS *et al.*, 2016). Entretanto, nas décadas seguintes a AM perdeu cerca de 20% da sua cobertura original.

5.2.1.2 Cerrado

O CE cobre \approx 25% do território nacional, perfazendo uma área que abrange o Distrito Federal, os estados de Goiás, Tocantins e Mato Grosso do Sul, e as regiões sul do Mato Grosso, oeste de Minas Gerais, oeste da Bahia, sul do Maranhão, oeste do Piauí e porções do Estado de São Paulo. Quase metade do CE já foi desmatado e apenas 54,5% de seu território ainda é coberto por vegetação nativa (MAPBIOMAS, 2022). A Savana brasileira é o maior hotspot de biodiversidade do Hemisfério Ocidental, considerado um dos 25 locais do planeta onde estão

concentrados $\approx 50\%$ de toda a biodiversidade global (MYERS *et al.*, 2000). No CE encontram-se as nascentes das três maiores bacias hidrográficas da América do Sul (Amazônica/Tocantins, São Francisco e Prata).

5.2.2 Dados

5.2.2.1 Clima

Como fonte de dados de precipitação utilizamos as estimativas diárias provenientes do satélite TRMM (*Tropical Rainfall Measuring Mission*) produto 3B42 V7 (mm.dia⁻¹) originalmente com resolução espacial de $\approx 28 \times 28$ km. Diversas pesquisas tem verificado e validado a efetividade destes dados na reprodução do regime de chuvas da região Amazônica (NÓBREGA; SOUZA; GALVÍNCIO, 2008; PAIVA *et al.*, 2011; CLARKE *et al.*, 2011) e na região central do Brasil, incluindo grandes áreas do CE (OLIVEIRA *et al.*, 2014; COLLISCHONN *et al.*, 2007). Como fonte de dados de temperaturas máxima e mínima (°C) utilizamos o banco de dados de (XAVIER *et al.*, 2022) com pixels com resolução espacial de 1x1km de variáveis climáticas para o período de 1961-2020. Os dados de Xavier e colaboradores possuem uma alta correlação quando comparado com os dados medidos in situ na validação cruzada ($r^2 \approx 0,8-0,9$).

5.2.2.2 Perda florestal

Para o Bioma AM utilizamos as taxas anuais de desmatamento oficiais estimadas pelo PRODES de 1999 a 2019 (Projeto de Monitoramento do Desmatamento na AM por Satélites) elaborado pelo Instituto Nacional de Pesquisas Espaciais. O PRODES emprega majoritariamente imagens Landsat numa combinação que busca minimizar o problema da cobertura de nuvens e garantir critérios de interoperabilidade. Entretanto, os dados do PRODES para o CE são bianuais até 2013, o que inviabiliza o seu uso neste trabalho. Como alternativa utilizamos os dados da classificação de uso e cobertura do solo do projeto MapBiomas coleção 6 (MAPBIOMAS, 2021) gerados a partir de processos de classificação automática aplicada a imagens de satélite Landsat. Os dados de desmatamento do PRODES (para a AM) e do MapBiomas (para o CE) foram agregados em séries temporais de mapas com o percentual de área desmatada acumulada em cada pixel de 28 x 28 km.

5.2.2.3 Produtividade agrícola

Como fonte de dados de produtividade da soja e do milho segunda safra utilizamos o conjunto de dados *Global Dataset of Historical Yield* versão 1.3 com resolução espacial 0.5° (GDHY V1.3; IIZUMI; SAKAI, 2020). O GDHY foi criado a partir de estatísticas de censos agrícolas e imagens de satélites e oferece séries históricas anuais de produtividade em ton/ha das principais culturas em todo o mundo com uma separação explícita das épocas de cultivo para algumas delas (Primeira e segunda safras ou cultivos de inverno e verão).

LIZUMI & SAKAI. 2020 estimaram a produtividade em cada célula foi estimada utilizando índices de vegetação derivados de satélite em associação com as estatísticas de produtividade relatadas pela FAO (Organização das Nações Unidas para a Alimentação e a Agricultura) provenientes de censos agrícolas. A área colhida possui referência em 2000 (MONFREDA; RAMANKUTTY; FOLEY, 2008), visto que não está disponível um mapa de área colhida variável no tempo para qualquer versão do GDHY. Comparações com diferentes bases de dados de produtividade demonstram que este conjunto é uma fonte assertiva de informações sobre produtividades (IIZUMI; SAKAI, 2020).

5.2.3 Início da estação chuvosa

O sistema de plantio duplo soja-milho é altamente dependente da longa estação chuvosa que proporciona tempo suficiente para que ambas as culturas sejam cultivadas ainda sob condições climáticas favoráveis. Neste contexto, o início da estação chuvosa foi identificado em cada pixel ao longo do tempo através do método *anomalous accumulation* (AA; Equação 5.1; LIEBMANN, 2007) Este método foi usado com sucesso para o mesmo fim no estado do Mato Grosso e no sul da AM (ARVOR *et al.*, 2014 LEITE-FILHO; COSTA; RONG, 2019b).

Para que pudéssemos identificar com maior precisão a transição do período seco para a estação chuvosa, nosso ano hidrológico se inicia no mês de setembro, visto que o período de chuvas na região Amazônica e no CE é compreendido em média, entre outubro e março, e o período seco entre maio e setembro. O AA possui uma aplicação direta para o setor agrícola ao considerar a demanda hídrica de uma planta em desenvolvimento como valor de referência (R_{ref}). O AA ($\text{mm} \cdot \text{dia}^{-1}$) é definido por:

$$AA^{(\text{day})} = \sum_{n=1}^{\text{day}} (R_n - R_{ref}) \quad (\text{Equação 5.1})$$

onde R_n é a chuva no dia n e R_{ref} é um valor de chuva de referência, ambos em mm.dia^{-1} . Considerando as aplicações agrícolas deste estudo, o R_{ref} foi fixado em 2.5 mm.dia^{-1} , representativo das necessidades de uma muda de cultivar de soja (ABRAHÃO; COSTA, 2018). A data de início é definida como o dia mínimo de AA. Assim, o início do período é selecionado como o dia a partir do qual AA permanece positivo durante o período mais longo.

5.2.4 Períodos de cultivo

Nas últimas duas décadas a produção brasileira de milho cresceu rapidamente (MACEDO et al., 2012; RAUSCH; GIBBS, 2016; NEPSTAD et al., 2014). Entretanto a área do milho plantado como primeira safra caiu pela metade. Atualmente $\approx 70\%$ da produção nacional de milho corresponde ao milho de sequeiro cultivado extemporaneamente, comumente de janeiro a abril, depois da soja precoce. Por isso, os dados de precipitação e de temperatura máxima e mínima entre 1999 e 2019 foram agrupados em dois períodos distintos: De setembro a dezembro, período no qual geralmente ocorre o cultivo da soja na AM (Primeira Safra) e de janeiro e abril, período no qual o milho é cultivado (Segunda safra). Esta divisão foi necessária visto que, cada safra é caracterizada por condições climáticas, manejo, estratégias e riscos diferentes, o que afeta diretamente o sucesso produtivo do sistema soja-milho. Portanto, estimar os riscos agroclimáticos em cada uma das fases reveste-se de importância estratégica para os agricultores.

5.2.5 Resíduos de precipitação, temperatura e início da estação chuvosa

Nosso objetivo central é estimar os riscos agroclimáticos sob diferentes níveis de desmatamento. Portanto, inicialmente foi necessário remover os efeitos de outros fatores (além do desmatamento) que podem afetar o início da estação chuvosa, o volume de chuvas e as temperaturas máxima e mínima na AM, tais como a posição geográfica e a variabilidade interanual do clima (associada aos mecanismos climáticos de larga escala). Dessa forma isolamos os efeitos do desmatamento dos efeitos da variabilidade natural do clima. Este processo foi conduzido através de uma metodologia adaptada de LEITE-FILHO *et al.*, 2021, composta por 3 passos (Descrita detalhadamente no material suplementar).

No passo 1 aplicamos modelos de regressão linear e não linear utilizando a posição geográfica (Latitude – φ e Longitude - λ) de cada pixel e sua altitude média (ζ) como variáveis predictoras para estimar os valores de precipitação, temperatura e início da estação chuvosa na

primeira e segunda safras. Incluímos também a interação entre as variáveis latitude, longitude e altitude visando explorar o melhor ajuste aos dados observados. A efetividade dos modelos testados em simular o padrão espacial da precipitação foi avaliada através da análise da distância entre os pontos de dados medidos pelo satélite TRMM e os valores estimados pelos nossos modelos sendo selecionados os modelos com o menor erro padrão residual, ou seja, o menor desvio padrão dos resíduos.

No passo 2 removemos as tendências climatológicas ligadas à localização geográfica e elevação. Para isso calculamos a diferença entre os valores brutos de precipitação, temperatura e início da estação chuvosa na primeira e segunda safras e os valores estimados devido à posição geográfica obtidos no passo 1. Entretanto, além da localização geográfica e altitude, os mecanismos climáticos interanuais de larga escala também influenciam no clima. Neste sentido, como os coeficientes das equações obtidas no passo 1 são estáticos ao longo do tempo, os resultados do passo 2 representam o desvio observado (resíduo) em relação ao padrão climatológico devido à variabilidade interanual do clima.

Uma vez que a nossa série temporal é relativamente curta (20 anos), pode existir um enviesamento para índices mais elevados do Nino 3.4, possivelmente associado a um ciclo parcial da Oscilação Decadal do Pacífico (ENSO; principal mecanismo de variabilidade interanual do clima que afeta nossa região de estudo). Além disso, como as perdas florestais na região do estudo aumentam monotonicamente em função do tempo, esta tendência de Nino 3.4 coincidindo com as perdas florestais pode enviesar nossas análises.

No passo 3 visamos remover o sinal de fatores de larga escala (como o sinal da ENSO (WANG; FIEDLER, 2006)). Para isso, subtraímos a precipitação média anual para toda a região do estudo dos resultados das equações do passo 2. Assumimos que o resultado deste último passo, ou seja, os resíduos climáticos estimados para o período da primeira e segunda safras, são os “resíduos” não explicadas pela localização geográfica, elevação ou fatores de larga escala variáveis no tempo. Ou seja, são consideradas o sinal do desmatamento no clima.

5.2.6 Resíduos de produtividade

Para identificar adequadamente os efeitos das mudanças no clima regional na produtividade da soja e do milho segunda safra foi necessário eliminar ruídos relacionados a outros fatores que também poderiam enviesar as nossas análises e impactar a eficiência dos

nossos estimadores e conseqüentemente a confiabilidade dos nossos resultados. Por exemplo, uma tendência de produtividade positiva durante um período de chuvas escassas não significa que a seca seja benéfica, uma vez que o avanço da tecnologia tais como mecanização, adoção de novas variedades, irrigação e fertilização do solo, dentre outros fatores, impulsionam as tendências de produtividade da soja e do milho.

Para que o efeito do desmatamento fosse isolado do efeito causado pelo desenvolvimento tecnológico, calculamos resíduos de produtividade da soja e do milho em 3 passos. No passo 1 testamos 3 modelos estatísticos (Polinomial de grau dois, linear e exponencial) para verificar quais deles se ajustavam melhor às séries históricas de produtividade em cada pixel de 28km x 28km ao longo do tempo. Determinamos a qualidade do ajuste de cada um dos modelos através do teste F a um nível de confiança de 95% (Material suplementar). Então, no passo 2, consideramos que os valores de produtividade da soja e do milho observados (y_t) reduzidos dos valores ajustados (\hat{y}_t) denotam a influência estocástica do clima e outros fatores de difícil previsão, ou seja, os resíduos de produtividade (ε_t) (equação 5.2; Ray et al., 2013). Então, para eliminar a tendência gradual de crescimento na produtividade devido ao avanço tecnológico, removemos os valores de produtividade da soja e do milho ajustados.

$$y_t = \hat{y}_t + \varepsilon_t, t = 1, 2, \dots, t. \text{ (Equação 5.2)}$$

Nossas análises foram conduzidas puramente a partir dos resíduos (ε), visto que estes incorporam os impactos aleatórios do clima sobre a produtividade das safras de soja e milho. Assim, garantimos que as nossas análises não fossem influenciadas por tendências comuns nos dados e que, de certa forma poderiam mascarar ou exacerbar os riscos agroclimáticos associados pelo desmatamento.

5.2.7 Testes de Granger

Para confirmar que as séries temporais de desmatamento são úteis na previsão dos resíduos climáticos (item 5.2.5) aplicamos o teste de causalidade de Granger (GRANGER, 1980; $\alpha = 0.05$) para investigar se valores passados de desmatamento ajudam a prever as alterações no clima (GRANGER, 1969). Vários estudos foram realizados aplicando o teste de Granger no âmbito da atribuição climática (WANG *et al.*, 2004; ELSNER, 2007; MOSEDALE *et al.*, 2006; KAUFMANN *et al.*, 2007; MOKHOV *et al.*, 2011). A significância estatística das

relações entre os resíduos climáticos e o desmatamento podem ser enxergadas como verificações e validações da metodologia de cálculo dos resíduos climáticos.

Por fim, para demonstrar que essa relação (Desmatamento \rightarrow Clima) é significativamente maior do que um efeito potencialmente reverso (Como por exemplo demonstrado por (STAAL *et al.*, 2020), também realizamos os testes de Granger na direção oposta (Clima \rightarrow Desmatamento). Testamos se as alterações climáticas são úteis na previsão de mudanças nos índices de desmatamento. Entretanto, de antemão ressaltamos que as alterações climáticas não demonstraram potencialidade de predição estatisticamente significativa ($p < 0.05$) das taxas de desmatamento nos testes executados, corroborando com as conclusões de LEITE-FILHO *et al.*, 2021.

5.2.8 Riscos agroclimáticos associados ao desmatamento

Embora não seja possível controlar plenamente muitos dos riscos agroclimáticos envolvidos na produção agrícola, há, a possibilidade de quantificá-los em função da frequência de eventos históricos. Partindo desta abordagem os resíduos climáticos previamente calculadas para os períodos de cultivo da primeira e segunda safras foram classificadas de acordo com o percentual de desmatamento acumulado observado em cada pixel de 28 x 28km. Para isso foram definidos cinco intervalos: o intervalo 1 inclui os resíduos climáticos estimados nos pixels com <20% da sua área desmatada; O intervalo 2 inclui os resíduos climáticos estimados nos pixels com área desmatada acumulada entre 20% e 40%; e assim sucessivamente, até o intervalo 5, com desmatamento entre 80% e 100%. Em seguida, para cada espaço amostral constituído pelos resíduos climáticos em cada intervalo de desmatamento aplicamos o método de simulação de Monte Carlo através do algoritmo de Metropolis (MC; METROPOLIS, 1987) para calcular as probabilidades de ocorrência dos resíduos climáticos associados. Na prática, para cada espaço amostral composto pelos resíduos climáticos de cada intervalo de desmatamento, o método de MC gerou números aleatórios, em um processo que produziu uma sequência (U_1, U_1, \dots) de valores no intervalo (0, 1) utilizando as funções densidade de probabilidade ajustadas aos dados. Então, para que tivéssemos maior segurança sobre o comportamento característico dos resíduos em cada intervalo de desmatamento a simulação foi repetida 10.000 vezes.

Após cada interação os dados foram armazenados e, ao final de todas as repetições, a sequência de resultados foi transformada em uma curva de distribuição de frequência. Assim, foi possível associar probabilidades de ocorrência dos resíduos climáticos de acordo com o

intervalo de desmatamento no qual ele se encontra, ou seja, de acordo com o grau de conservação florestal de cada pixel. Consideramos que as probabilidades de ocorrência de um risco podem ser expressas como uma probabilidade, sendo um número entre 0 e 1 (ou 0 e 100%), com 0.0 equivalendo a uma situação a qual nunca irá acontecer, e 1.0 como que sempre irá ocorrer.

5.3 RESULTADOS E DISCUSSÃO

5.3.1 Testes de Granger

Nossos resultados demonstram que as séries temporais de área desmatada acumulada são úteis na previsão das mudanças climáticas locais e regionais em ambos os biomas em uma escala regional (28km x 28km). Adicionalmente as mudanças locais e regionais na sazonalidade e volume das chuvas e nos padrões de temperatura ligadas ao desmatamento são úteis na previsão das variações na produtividade da soja e do milho plantados nestas regiões (Figura 5.1).

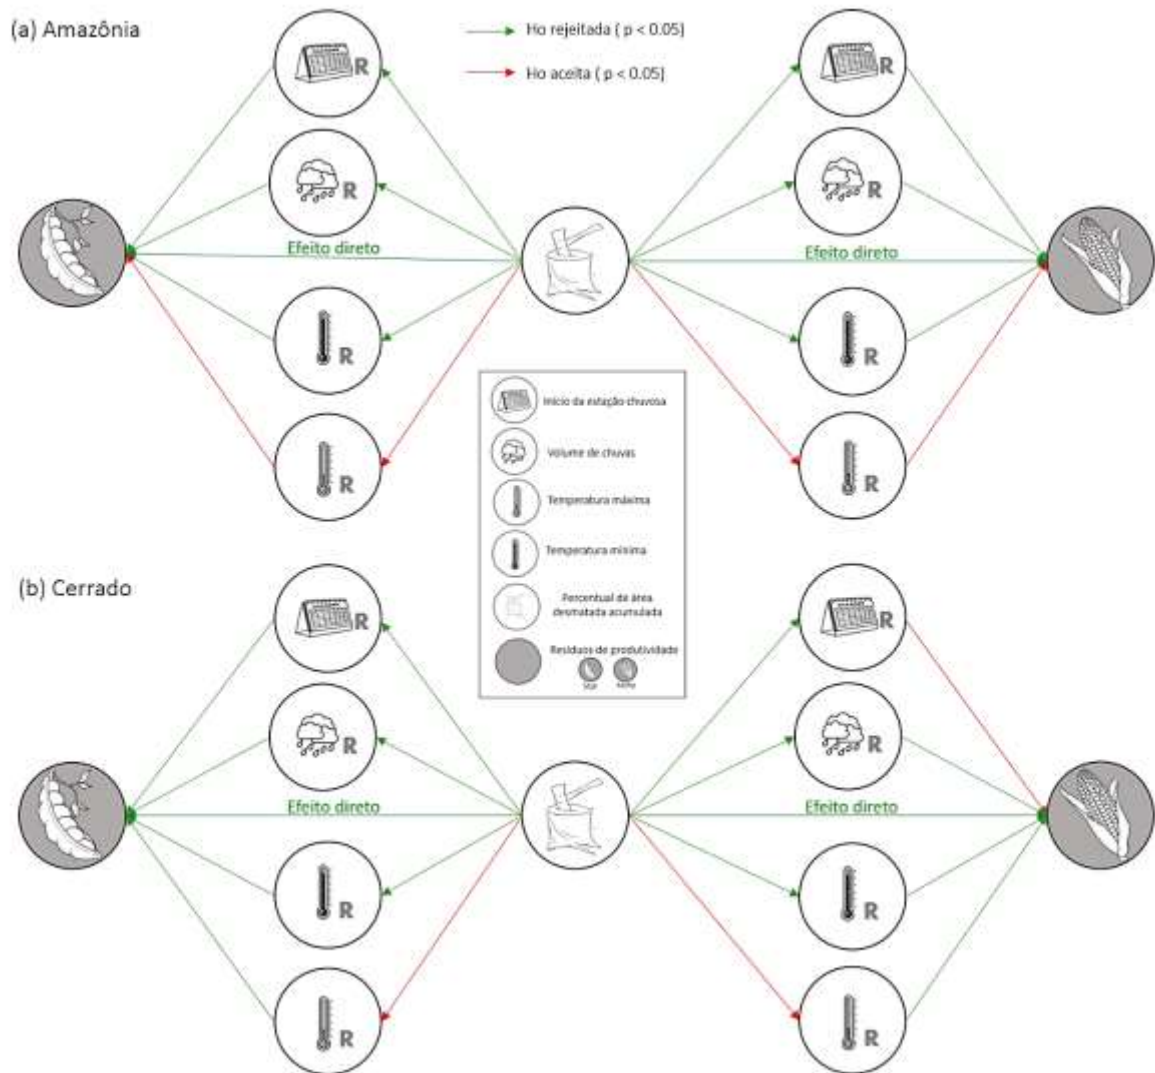


Figura 5.1: Resultados dos testes de Granger entre desmatamento, clima e produtividade agrícola.

5.3.1.1 Testes de Granger entre desmatamento e clima

Tanto na AM (Tabela 5.5) quanto no CE (Onde, D = Área desmatada acumulada, OA = Resíduos do início da estação chuvosa devido ao desmatamento, RA = Resíduos do volume de chuvas devido ao desmatamento, $MaxTA$ = Resíduos da temperatura máxima devido ao desmatamento, $MinTA$ = Resíduos da temperatura mínima devido ao desmatamento.

), a hipótese nula de não causalidade de Granger entre o desmatamento e os resíduos de chuvas e temperatura máxima é rejeitada em ambas as safras ($\alpha = 0.05$). Entretanto, para os resíduos de temperatura mínima da primeira safra, a hipótese nula de não causalidade é aceita.

Em ambos os biomas a sazonalidade das chuvas também se mostrou dependente do estado de conservação florestal na escala analisada. A hipótese nula de Granger do poder das séries temporais de desmatamento efeito do desmatamento em não predizerem o início do período chuvoso foi rejeitada ao nível de significância de 5%, corroborando com recente literatura científica que reforça através de evidências empíricas de que o desmatamento atrasa o início do período chuvoso (BUTT; OLIVEIRA; COSTA, 2011; DEBORTOLI *et al.*, 2015; DEBORTOLI *et al.*, 2016; LEITE-FILHO; PONTES; COSTA, 2019a, LEITE-FILHO; COSTA; RONG, 2019b).

Tabela 5.5: Resultados dos testes de Granger entre o desmatamento e a variabilidade climática na Amazônia para a primeira e segunda safras entre 1999 e 2019.

	Hipótese nula	F-Statistic	Probabilidade
	D Does not Granger cause OA	0.0405	0.8406
	D Does not Granger cause RA	1.4208	0.2417
Primeira safra	D Does not Granger cause MaxTA	0.1332	0.7152
	D Does not Granger cause MinTA	5.8739	0.01543
	D Does not Granger cause RA	0.7332	0.5134
Segunda safra	D Does not Granger cause MaxTA	0.8842	0.4132
	D Does not Granger cause MinTA	1.8937	0.1507

Onde, D = Área desmatada acumulada, OA = Resíduos do início da estação chuvosa devido ao desmatamento, RA = Resíduos do volume de chuvas devido ao desmatamento, MaxTA = Resíduos da temperatura máxima devido ao desmatamento, MinTA= Resíduos da temperatura mínima devido ao desmatamento.

5.3.1.2 Testes de Granger entre clima e produtividade

Tanto na AM (Tabela 5.7) quanto no CE (Tabela 5.7), a hipótese nula de não causalidade de Granger entre os resíduos de chuvas e temperatura máxima e a produtividade da soja e do milho é rejeitada em ambas as safras ($\alpha = 0.05$). Ou seja, as mudanças climáticas locais e

regionais causados pelo desmatamento são preditoras das alterações de produtividade das lavouras de grãos da AM e CE.

Tabela 5.6: Resultados dos testes de Granger entre a variabilidade climática e a produtividade da soja e do milho segunda safra produzidos na Amazônia entre 1999 e 2019.

	Hipótese nula	Estatística F	Probabilidade
Primeira safra	OR Does not Granger cause YR	0.1258	0.9788
	RR Does not Granger cause YR	0.5508	0.7269
	MaxTR Does not Granger cause YR	0.5368	0.7288
	MinTR Does not Granger cause YR	3.2436	0.0093
Segunda safra	OR Does not Granger cause YR	3.5623	0.0381
	RR Does not Granger cause YR	0.4184	0.6619
	MaxTR Does not Granger cause YR	0.5527	0.5801
	MinTR Does not Granger cause YR	0.5027	0.6125

Onde, D = Área desmatada acumulada, OA = Resíduos do início da estação chuvosa devido ao desmatamento, RA = Resíduos do volume de chuvas devido ao desmatamento, MaxTA = Resíduos da temperatura máxima devido ao desmatamento, MinTA= Resíduos da temperatura mínima devido ao desmatamento e YA = Resíduos de produtividade (Soja ou milho).

Tabela 5.7: Resultados dos testes de Granger entre a variabilidade climática e a produtividade da soja e do milho segunda safra produzidos no Cerrado entre 1999 e 2019.

	Hipótese nula	Estatística F	Probabilidade
	OA Does not Granger cause YA	0.5473	0.5876

Primeira safra	RA Does not Granger cause YA	0.2793	0.7058
	MaxTA Does not Granger cause YA	0.3735	0.6812
	MinTA Does not Granger cause YA	0.5566	0.5978
Segunda safra	OA Does not Granger cause YA	6.8976	0.0031
	RA Does not Granger cause YA	0.3092	0.7355
	MaxTA Does not Granger cause YA	1.3811	0.2318
	MinTA Does not Granger cause YA	0.6018	0.6121

5.3.2 Riscos agroclimáticos associados ao desmatamento

A análise comparativa das curvas advindas do método de MC (seção 5.2.5) alerta para o risco agroclimático aumentado em função do desmatamento da AM e CE. Durante a janela de plantio da primeira e segunda safras a sazonalidade e o volume de chuvas são afetados pela remoção da vegetação nativa, bem como os as temperaturas mínima e máxima aumentam. Em outras palavras, a razão pelas quais deve-se a AM e o CE não apenas ideológicas. São hidrológicas, climatológicas e geoquímicas.

5.3.2.1 Atraso no início da estação chuvosa

As funções densidade de probabilidade dos resíduos de início da estação chuvosa em cada intervalo de desmatamento apontam para maiores taxas de desmatamento associadas a riscos mais elevados de atrasos no início da estação chuvosa e conseqüentemente no início da semeadura da soja tanto na AM (Figura 5.2a) quanto no CE (Figura 5.2b).

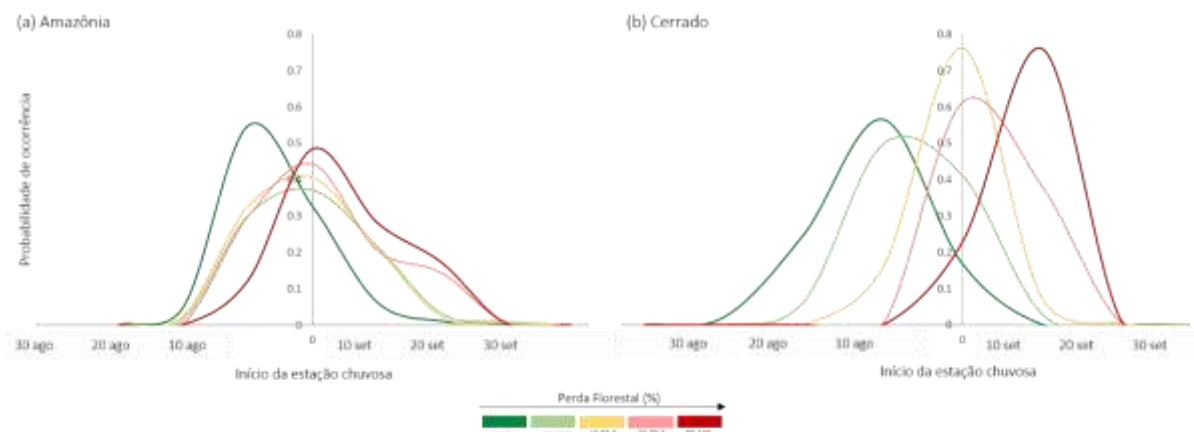


Figura 5.2: Curvas de probabilidade de ocorrência dos resíduos de início da estação chuvosa para diferentes intervalos de desmatamento na (a) Amazônia e (b) Cerrado.

Esses resultados são consistentes com o mecanismo de bomba de umidade por convecção rasa proposto por WRIGHT *et al.*, 2017. A precipitação que mantém o ciclo hidrológico amazônico está ligada à migração sazonal da zona de convergência intertropical e à baixa circulação a ela associada, que muda de posição de zonal para nordeste ao longo do ciclo anual e modela a monção sul-americana durante a estação chuvosa (VERA *et al.*, 2006). Além disso, a reciclagem de precipitação (isto é, a cascata de umidade através da precipitação, evapotranspiração e ciclos subsequentes de precipitação) – especialmente durante a estação seca – é uma fonte crítica de umidade para a floresta tropical interna e estima-se que contribua com 20-30% da chuva sobre a bacia amazônica (SPRACKLEN; ARNOLD; TAYLOR, 2012; VAN DER ENT *et al.*, 2010; ZEMP *et al.*, 2014). A evapotranspiração do dossel também é influente na estação de transição seco-úmido, umedecendo a atmosfera inferior e média nos meses que antecederam a monção e preparando a troposfera para uma convecção profunda (FU; LI, 2004).

5.3.2.2 Redução no volume de chuvas

Os efeitos do desmatamento no transporte de umidade e na convecção também estão associados à maiores probabilidades de ocorrência de resíduos negativos no volume de chuvas em ambas as safras (Figura 5.3). Ou seja, além de afetar a janela de plantio, menores volumes de chuvas estão associados a regiões com maior percentual de área desmatada acumulada, aumentando o risco de quebras de produtividade já que a agricultura de sequeiro é dependente das chuvas e da água armazenada no solo (SUMILA *et al.*, 2017). Em outras palavras, a conservação da AM e CE possui potencial de reduzir os extremos hidroclimatológicos que levam a quebras de safras mais constantes e extensas. O desmatamento possui um papel fundamental principalmente nos anos nos quais as condições climáticas de larga escala (*El niño*, *La niña*) forem desfavoráveis, a exemplo da seca que atingiu a AM em 2010, a mais severa em 100 anos.

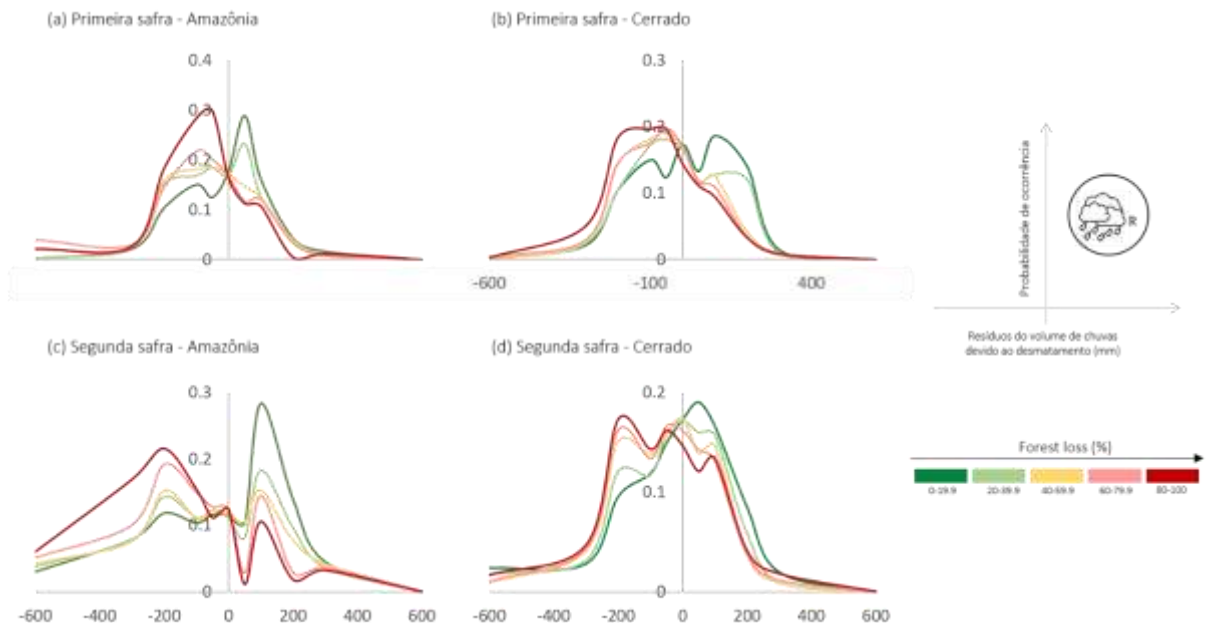


Figura 5.3: Curvas de probabilidade de ocorrência dos resíduos do volume de chuvas para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) Segunda safra na Amazônia e (d) Segunda safra no Cerrado.

5.3.2.3 Aquecimento do ar

Maiores riscos de aquecimento também são esperados nas áreas com desmatamento acumulado mais elevado, tanto nas temperaturas máximas (Figura 5.4), quanto nas mínimas (Figura 5.5). A remoção da floresta aumenta o albedo da superfície e reduz a radiação líquida (Figura 5.5). Quando comparadas a áreas florestadas, as áreas desmatadas têm maior albedo (18% em comparação com 13%; CULF; FISCH; HODNETT, 1995). Além disso, o desmatamento muda a partição da radiação líquida (em fluxo de calor latente e sensível), que, com menor capacidade de armazenamento de umidade do solo e solos mais secos, contribuem para diminuição do fluxo de calor latente. A terra desmatada pode ter um fluxo de calor latente 30% menor do que a terra florestada (GASH *et al.*, 1996), culminando em temperaturas mais alta.




Figura 5.4: Curvas de probabilidade de ocorrência dos resíduos de Temperatura máxima para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) Segunda safra na Amazônia e (d) Segunda safra no Cerrado.

Embora a conservação florestal cause um arrefecimento mais expressivo nas temperaturas máximas, as mínimas também se elevam na ausência da vegetação (Figura 5.5). Além de afetar as atividades fotossintéticas da soja e do milho, o aquecimento resulta no aumento do consumo de água pelos produtores rurais e na redução da disponibilidade de água, que, em associação com os impactos no volume e sazonalidade das chuvas impõe fortes ameaças à capacidade de produção de grãos nestas regiões. Ainda, em locais em que a temperatura se eleva, espera-se um aumento na atividade metabólica e alimentícia dos insetos-praga (SKENDŽIC *et al.*, 2021).

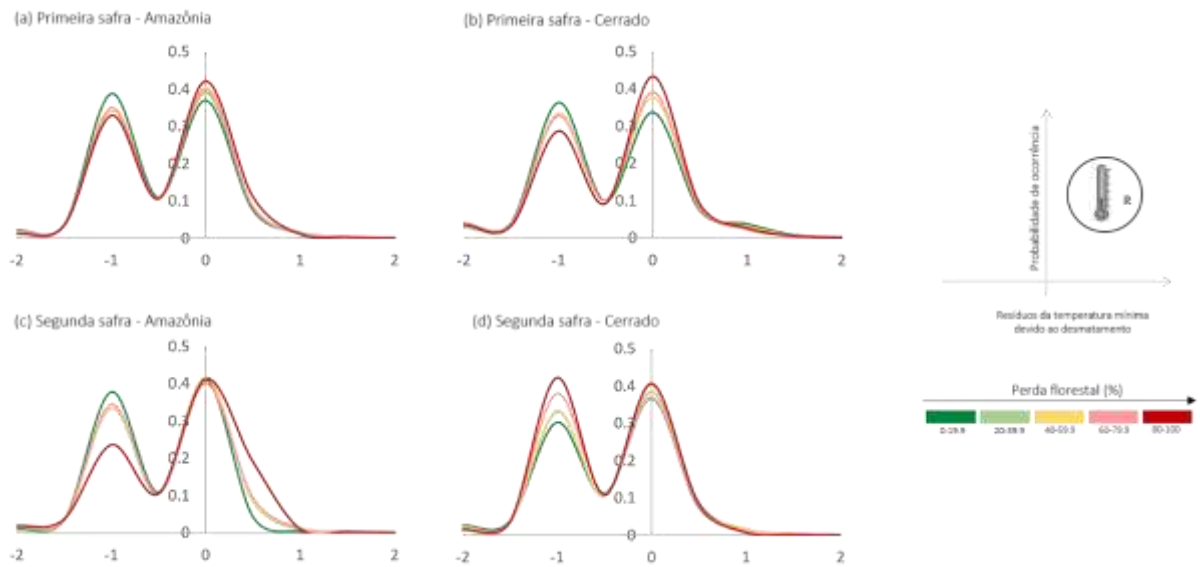


Figura 5.5: Curvas de probabilidade de ocorrência dos resíduos de Temperatura mínima para diferentes intervalos de desmatamento na (a) Primeira safra na Amazônia; (b) Primeira safra no Cerrado; (c) Segunda safra na Amazônia e (d) Segunda safra no Cerrado.

5.3.3 A conservação ambiental e a mitigação dos riscos agroclimáticos

As vantagens de se praticar um sistema de cultivo duplo intensivo de baixo risco agroclimático expandem os benefícios da conservação florestal, colocando o controle do desmatamento em uma nova perspectiva. Uma breve análise do Código Florestal vigente no País (Lei nº 12.651; BRASIL, 2012) deixa claro os benefícios agroclimáticos de se cumprir o que foi estabelecido por lei. Ou seja, manter o desmatamento dentro do limite permitido por lei não é apenas uma questão de ter mais acesso ao crédito agrícola subsidiado (disponível apenas para quem cumpre a lei) ou simplesmente não ser multado. Os benefícios da conservação se expandem ao agronegócio exportador ali atuante.

5.3.3.1 Amazônia

De acordo com o Código Florestal do Brasil (Lei nº 12.651; BRASIL, 2012), 80% das terras privadas na AM devem ser protegidas. Portanto, de acordo com as probabilidades de ocorrência dos resíduos climáticos em cada intervalo de desmatamento (item 3.6), em uma região com desmatamento permitido por lei (20%), o risco médio de que o período chuvoso comece 1 a 2 semanas mais tarde em comparação à climatologia local, é em média, de apenas ≈6%. Já o risco de diminuição de 15 a 30% do volume de chuvas na primeira safra é em média

≈15%, e o risco das temperaturas máximas e mínimas médias aumentarem 1°C a 1.5°C em relação à normal climatológica é em média ≈2% e ≈7%, respectivamente. Por outro lado, em um caso de desmatamento maior do que o permitido por lei, por exemplo, em uma região de 28km x 28km de resolução espacial com 80% de sua área desmatada, os riscos deste mesmo atraso no início do período chuvoso e de diminuição das chuvas na primeira safra sobe para ≈28%, ao passo que o risco de as temperaturas máximas aumentarem 1° a 1.5°C sobe para ≈15%.

Para a segunda safra os riscos agroclimáticos também são maiores quando a legislação não é cumprida. O risco médio de diminuição de 15 a 30% do volume normal de chuvas é em média 11%, o risco de temperaturas máximas 1°C a 1.5°C mais quentes é em média ≈7%. Em um caso de desmatamento extremo de 80%, o risco de diminuição das chuvas na safra sobe para ≈22%, ao passo que o risco de temperaturas máximas 1°C a 1.5°C mais quentes sobe para ≈15%. Já o risco de temperaturas mínimas 0.5°C a 1°C mais quentes é em média de ≈19%.

Para o CE, a legislação define que todo imóvel rural que estiver dentro da Amazônia Legal deve manter 35% da sua área com cobertura de vegetação nativa, a título de Reserva Legal (Lei nº 12.651; BRASIL, 2012), ao passo em que as regiões de CE localizados fora da Amazônia Legal devem manter 20%, exceto no estado do Piauí. Considerando esses limites, e de acordo com as probabilidades de ocorrência dos resíduos climáticos em cada intervalo de desmatamento derivadas do método de MC, o risco médio de que a período chuvoso comece 1 a 2 semanas mais tarde é, em média, de apenas ≈6% em regiões com o desmatamento dentro dos limiares permitidos por lei. Já o risco de diminuição de 15 a 30% do volume de chuvas na primeira safra é em média ≈15%, e o risco das temperaturas máximas e mínimas médias aumentarem 1°C a 1.5°C em relação à normal climatológica é em média ≈2% e ≈7%, respectivamente. Por outro lado, em um caso de desmatamento maior do que o permitido por lei, por exemplo, um desmatamento extremo de 80% (limite máximo de desmatamento no CE localizado fora da Amazônia Legal), os riscos deste mesmo atraso no início do período chuvoso e de diminuição das chuvas na primeira safra sobe para ≈28%, ao passo que o risco das temperaturas máximas se aquecerem 1° a 1.5°C sobe para ≈15%.

Para a segunda safra os riscos agroclimáticos também são maiores quando a legislação não é cumprida. O risco médio de diminuição de 15 a 30% do volume normal de chuvas é em média 11%, o risco de temperaturas máximas 1°C a 1.5°C mais quentes é em média ≈7%. Em

um caso de desmatamento extremo de 80%, o risco de diminuição das chuvas na safra sobe para $\approx 22\%$, ao passo que o risco de temperaturas máximas 1°C a 1.5°C mais quentes sobe para $\approx 15\%$. Já o risco de temperaturas mínimas 0.5°C a 1°C mais quentes é em média de $\approx 19\%$. Dessa forma, elevam-se os riscos agroclimáticos para a agricultura, deixando algumas regiões mais susceptíveis aos efeitos da crise climática global. Ou seja, manter o desmatamento na AM e no CE dentro do limite permitido por lei também não é apenas uma questão burocrática. Os benefícios da conservação se expandem aos cultivos ali plantados.

5.4 CONCLUSÕES

Este artigo apresenta uma conexão empírica entre o início da estação chuvosa, o volume de chuvas e os padrões de temperatura máxima e mínima com o desmatamento durante a janela de cultivo da primeira e segunda safras na AM e no CE. Fazendo uso de dados temporal e espacialmente explícitos sobre o uso da terra e desmatamento, produtividade agrícola e clima, demonstramos a conexão entre as modificações climáticas induzidas pelo desmatamento e a produtividade da soja e do milho colhidos nas principais áreas produtoras de grãos do Brasil.

Em resumo, este estudo apresenta evidências que demonstram as mudanças no uso da terra, particularmente do desmatamento como preditora de modificações climáticas regionais no Brasil. Ao remover as influências associadas à localização geográfica e à variabilidade interanual, evidenciamos o papel do desmatamento no aumento do risco agroclimático de atrasos no início da estação chuvosa (e conseqüentemente na data de semeadura da primeira safra), redução do volume de chuvas e aumento das temperaturas durante o cultivo da soja e do milho.

Esses resultados possuem um importante papel para o planejamento regional do uso da terra e para aumentar a resiliência da produção de grãos do Brasil frente à variabilidade climática. Manter o desmatamento em níveis baixos é importante para que os agricultores se beneficiem de chuvas regulares e em volumes suficientes, além de condições de temperaturas amenas essenciais para os sistemas intensivos de cultivo duplo soja-milho. A capacidade do agronegócio brasileiro em manter ou elevar a produção de grãos depende da habilidade do setor em conciliar a produção em larga escala com a conservação dos remanescentes naturais já que as práticas agrícolas são diretamente afetadas pelo clima regulado por essas florestas.

6 CAPÍTULO 3:

A CONTA DO DESMATAMENTO E DA VARIABILIDADE CLIMÁTICA PARA O AGRONEGÓCIO BRASILEIRO

Artigo em preparação

Resumo

O agronegócio é um vetor crucial do crescimento do Brasil. Prova disso são os diversos recordes de grãos produzidos e receita com as exportações ao longo dos últimos anos. Entretanto, para a preocupação do País, a agricultura é um dos setores da economia mais suscetíveis às variações climáticas. Não obstante, perdas irreversíveis na produção de grãos têm sido registradas em decorrência do clima extremo. Para investigar a conexão quantitativa entre o volume e a sazonalidade das chuvas, o desmatamento e a produtividade da soja e do milho no Cerrado e Amazônia Brasileira (AM) nas últimas décadas utilizamos dados temporal e espacialmente explícitos sobre o uso da terra e variáveis meteorológicas em associação com estatísticas oficiais de produção e produtividade agrícolas. Exploramos os determinantes espaciais das quebras e ganhos de produtividade e quantificamos os impactos econômicos diretos e indiretos do desmatamento na rentabilidade dos produtores e na receita atingida com as exportações entre 1999 e 2019. A sazonalidade e volume das chuvas e os padrões de temperatura em ambos os biomas apresentam tendência de mudança, indicando que o clima não está dentro da sua variabilidade normal. Ao mesmo tempo, as séries históricas de produção, produtividade e área plantada com o sistema dupla safra soja-milho indica que o crescimento da produção ocorreu principalmente pela incorporação de novas áreas ao processo produtivo. As quebras de produtividade da soja e do milho tem ocorrido mais frequentemente e recentemente, fazendo com que o Brasil deixasse de produzir ≈ 23 milhões de toneladas de grãos, refletindo na renda dos produtores e na economia nacional. Entre 2003 e 2019 o sistema DC na AM perdeu mais de US\$ 8.5 bilhões, o equivalente a \approx US\$ 602.4 milhões/ano. No CE as perdas acarretaram um prejuízo potencial de US\$ ≈ 23.8 bilhões ou \approx US\$ 1.7 bilhões/ano. A nível nacional, as perdas econômicas potenciais para a cultura da soja alcançam US\$ ≈ 21.6 bilhões na Primeira safra e 10.7 bilhões na segunda safra (9% e 7% da produção brasileira de soja e milho colhida no mesmo período). Direta ou indiretamente o desmatamento explica 9% e 5% das variações na produtividade da soja na AM e CE ao longo deste período, ao passo em que representam, 3% e 5% das variações na produtividade do milho. O desmatamento da AM gerou perdas econômicas de US\$ 388.2 milhões aos agricultores na região (\approx US\$ 27,7 milhões por ano), ao passo em que o desmatamento do CE gerou perdas potenciais de US\$ 925,5 milhões (\approx US\$ 66,1 milhões por ano). Reduzir ou zerar o desmatamento pode mitigar os efeitos agroclimáticos adversos que afetam o volume de grãos produzidos e a receita atingida com as exportações.

6.1 INTRODUÇÃO

O Agronegócio foi responsável por quase metade das exportações brasileiras em 2021 (CASTRO *et al.*, 2022). O País exportou um recorde de 86,6 milhões de toneladas de soja, ante 82,3 milhões no ano anterior (CONAB, 2022). Além do aumento expressivo na produção de soja, mais de 70% dos cultivos brasileiros adotam o milho como segunda safra (Sistema DC) visando intensificar o uso da terra e aumentar a produção. Atualmente $\approx 70\%$ da produção nacional de milho corresponde ao milho proveniente do sistema DC (CONAB, 2022). Não obstante, nas últimas duas décadas a produção brasileira de grãos cresceu 3.5 vezes mais em comparação à média global (FAO, 2017). A soja e o milho brasileiros abastecem $\approx 50\%$ e $\approx 10\%$ do mercado global, respectivamente (TRASE, 2021). Somente a China, a União Europeia e o Reino Unido importam mais de 80% dos grãos brasileiros destinados ao mercado externo. Grande parte dos grãos são transformados em biocombustíveis ou são direcionados para a alimentação do gado visando suprir a crescente população que consome cada vez mais proteína de origem animal (LAMBIN; MEYFROIDT, 2011). Diante do constante aumento da demanda, o Brasil deve continuar ampliando sua contribuição para o abastecimento mundial a ponto de se tornar o maior exportador de grãos do planeta nos próximos cinco anos (MAPA, 2019).

Entretanto, apesar da tendência ascendente de produção, o agronegócio brasileiro enfrenta substanciais riscos agroclimáticos porque depende de um clima estável para desenvolver a sua própria produção. Com apenas 10% de sua área cultivada irrigada (ANA, 2017), a agricultura brasileira é altamente vulnerável a secas, ondas de calor e outras perturbações climáticas (COSTA *et al.*, 2019). Neste sentido, as mudanças climáticas globais (influenciadas pelo aquecimento global) e locais e regionais (relacionadas ao desmatamento) (SPERA *et al.*, 2016) podem frustrar as ambições do agronegócio brasileiro. O declínio da produção de grãos provavelmente seguirá os aumentos regionais na temperatura do ar (SILVÉRIO *et al.*, 2015), menor volume de chuvas (BARKHORDARIAN *et al.*, 2019, maior frequência e intensidade das secas (LEITE-FILHO *et al.*, 2020).

A instabilidade e os eventos climáticos extremos recentes oferecem insights importantes sobre como a produção de grãos brasileira pode responder a essas mudanças climáticas. Na safra 2020/21 produtores perderam até 50% (\approx US\$ 5,2 milhões) das lavouras de milho segunda safra no estado do Mato Grosso (maior produtor nacional de grãos), perda ainda maior nas lavouras plantadas tardiamente devido ao atraso no início da estação chuvosa. Pelo mesmo

motivo, a produção em Goiás (3º maior produtor nacional) foi menor que o ano agrícola passado. O impacto da seca na safra de soja 2021/2022 superaram US\$ 14 bilhões, das quais, 1 milhão de toneladas foram perdidas com o impacto das secas somente no estado do Mato Grosso do Sul (5º maior produção do país).

Apesar da importância do conhecimento dos impactos históricos da variabilidade do clima e do desmatamento na produção agrícola, poucos estudos se concentraram no entendimento dos determinantes causais do problema e nas perdas causadas à balança comercial do agronegócio brasileiro. Só através do conhecimento das causas das quebras de safra é possível embasar a melhoria da eficiência de políticas e programas públicos e privados, principalmente nas agendas agrícola e ambiental voltadas à resiliência do agronegócio brasileiro.

Neste contexto utilizamos dados históricos temporal e espacialmente explícitos sobre o uso da terra e variáveis meteorológicas em associação com estatísticas oficiais de produção e produtividade agrícolas (IBGE, 2022) Essa análise sinérgica destes dados representa uma melhoria significativa em relação às análises anteriores que se baseavam em xxxxxxxx. Usamos esses dados para responder a quatro perguntas centrais. Em primeiro lugar, qual é o padrão espacial de conversão de áreas nativas em grandes monoculturas exportadoras? Mostramos os movimentos dos plantios focados no cultivo duplo soja-milho longo do tempo e identificamos padrões de adensamento e agrupamento regional. Em segundo lugar, quais os determinantes espaciais das quebras e ganhos de produtividade

Quais os padrões de expansão dos cultivos DP?

O aumento de produção tem se dado devido ao aumento da área plantada ou dos incrementos de produtividade?

As quebras de produtividade tem acontecido com maior frequência e intensidade?

Quais os determinantes espaciais das quebras e ganhos de produtividade?

Quais os impactos econômicos diretos e indiretos do desmatamento e da variabilidade climática na rentabilidade dos produtores e consequentemente nas exportações do País entre 1999 e 2019?

Em segundo lugar, como a concorrência evoluiu dentro da indústria? Usamos um índice econômico de concentração de mercado para estabelecer se o abate de bovinos está concentrado em empresas específicas e como essa concentração evoluiu ao longo do tempo. Em terceiro, xxxx. E por fim, xxxx.

6.2 DADOS E MÉTODOS

6.2.1 Região

Nossa região de estudo inclui os dois maiores biomas da América Latina: Amazônia (4,2 milhões de km²) e Cerrado (1,9 milhões de km²), totalizando ≈80% do território brasileiro. Tanto a AM quanto o CE são essenciais para a provisão de serviços ecossistêmicos fundamentais para a agricultura, tais como, a garantia da qualidade do solo, ciclagem da água, proteção da biodiversidade e estocagem de Carbono (STRAND *et al.*, 2018). Porém, na contramão desse conhecimento científico, AM e CE concentraram 97% das áreas desmatadas no Brasil em 2021 (MAPBIOMAS, 2022). AM e CE são responsáveis por ≈25% e 52% da soja e do milho exportados pelo Brasil (IBGE, 2021). Das 13,6 milhões de toneladas de soja importadas pela União Europeia, 69% são produzidas nestes biomas (RAJÃO *et al.*, 2020).

Nossa região de estudo incorpora no todo ou em parte três das principais fronteiras agrícolas brasileiras da atualidade (RAD, 2021) (i) A região conhecida como “Arco do desmatamento”, onde a fronteira agrícola avança em direção à ao norte do País e também onde encontram-se os maiores índices de desmatamento da AM. São 500 mil km² de terras que vão do leste e sul do Pará em direção oeste, passando por Mato Grosso, Rondônia e Acre (citação); (ii) A região conhecida como “AMACRO”, nome dado ao polo agrícola formado pelo tríplice divisa entre os estados do Acre, Amazonas e Rondônia que vem sendo preparada para receber o boi e a soja por meio do desmatamento da AM. As cidades desta região ficaram nas primeiras posições como as mais desmatadas da AM, com destaque para os municípios de Lábrea e Apuí, que juntas representaram mais de 13% do total de alertas de devastação no Bioma (RAD, 2021); (iii) A região conhecida como MATOPIBA (destacada nos mapas deste artigo), formada pelos estados do Maranhão, Tocantins, Piauí e Bahia, responsável por 10% da produção brasileira de grãos. Do total de vegetação suprimida no CE entre agosto de 2020 e julho de 2021, 61,3% esteve concentrado na região (MAPBIOMAS, 2022).

6.2.1.1 Amazônia

A AM representa dois terços das florestas naturais do Brasil, cobrindo $\approx 50\%$ do território nacional. Além de abrigar mais da metade da biodiversidade do planeta, o Bioma é fundamental para a regulação climática e distribuição das chuvas na América do Sul através de um mecanismo em que a floresta atrai a umidade evaporada do oceano Atlântico e a transforma em chuva no continente (VAN DER ENT *et al.*, 2010). Por meio da transpiração das árvores, a água precipitada retorna para o ar como vapor. Essa massa de ar úmido, então, é empurrada pelo vento para a direção oeste e depois, ao atingir a Cordilheira dos Andes, para o sul, contribuindo para as chuvas nas regiões Centro-Oeste, Sul e Sudeste do Brasil, além de outros países como a Bolívia, a Argentina e o Paraguai.

6.2.1.2 Cerrado

Segundo maior bioma do Brasil, cobrindo 30% do território nacional, o CE é considerado o maior hotspot de biodiversidade do Hemisfério Ocidental, um dos 25 locais do Planeta onde estão concentrados $\approx 50\%$ de toda a biodiversidade global (MYERS *et al.*, 2000), destacando-se pela abundância de espécies endêmicas. Neste bioma encontram-se ainda as nascentes das três maiores bacias hidrográficas da América do Sul (Amazônica/Tocantins, São Francisco e Prata).

6.2.2 Dados

6.2.2.1 Clima

O IPCC define mudança climática como variações no clima que podem ser identificadas (usando testes estatísticos) por mudanças na média e/ou na variabilidade de suas propriedades e que persistem por um longo período, tipicamente décadas ou mais. Portanto, para avaliarmos a estacionariedade do clima na AM e CE utilizamos dados da reanálise ERA5, quinta geração de reanálises atmosféricas do European Centre for Medium-Range Weather Forecasts (ECMWF) de clima global com uma resolução espacial de 30km x 30km com resolução temporal horária, com dados de 1959 até o presente.

Para a modelagem diagnóstica dos determinantes das quebras ou ganhos de produtividade utilizamos os dados diários de precipitação de precipitação (mm.dia^{-1} ;) advindos do satélite Tropical Rainfall Measuring Mission (TRMM) 3B42 (versão 7; resolução espacial

de 28 x 28km) (HUFFMAN *et al.*, 2007). Para a contabilização dos padrões de temperatura utilizamos os dados de temperaturas máxima e mínima obtidos através do banco de dados Daily gridded meteorological variables in Brazil (XAVIER *et al.*, 2022) reamostrados em mapas com célula de grade de 28 x 28 km de forma a coincidir com as células do satélite TRMM.

Diversas pesquisas tem verificado e validado a efetividade destes dados para a representação do regime de chuvas na região amazônica (CLARKE *et al.*, 2011; NÓBREGA; SOUZA; GALVÍNICO, 2008; PAIVA *et al.*, 2011) e na região central do Brasil, incluindo grandes áreas do CE (COLLISCHONN *et al.*, 2007; OLIVEIRA *et al.*, 2014). Os dados de Xavier e colaboradores possuem uma alta correlação na validação cruzada quando comparado com os dados medidos in situ ($r^2 \approx 0,8-0,9$).

6.2.2.2 Produtividade agrícola

Obtivemos a produtividade média das lavouras de dupla safra (soja seguida do milho, em kg/ha) por município entre 2003 e 2019 a partir das informações disponíveis da Pesquisa de Produção Agrícola Municipal fornecidas pelo Instituto Brasileiro de Geografia e Estatística (PAM/IBGE, 2021). Os dados tabulares provenientes do sistema SIDRA/IBGE foram desagregados espacialmente de forma a permitir o cruzamento com dados climáticos em mapas de séries temporais com pixels de 28 x 28 km utilizando como método de interpolação a krigagem ordinária, geralmente aplicada à agricultura de precisão (GREGO; DE OLIVEIRA; VIEIRA, 2014). Essa técnica interpola os valores sem tendenciosidade e com desvios mínimos em relação aos valores conhecidos considerando a estrutura da variabilidade espacial dos dados amostrados

6.2.2.3 Perda Florestal

A perda florestal no Bioma AM foi obtida através das taxas anuais de desmatamento oficiais estimadas pelo PRODES (Projeto de Monitoramento do Desmatamento na AM por Satélites) elaborado pelo Instituto Nacional de Pesquisas Espaciais. Entretanto, os dados do PRODES para o CE são bianuais até 2013, inviabilizando o seu uso para o alcance dos objetivos propostos. Como alternativa utilizamos os dados da classificação de uso e cobertura do solo do projeto MapBiomas coleção 6 (MAPBIOMAS, 2021; SOUZA *et al.*, 2020) gerados a partir de processos de classificação automática aplicada a imagens de satélite Landsat. Os dados de desmatamento do PRODES (para a AM) e do MapBiomas (para o CE) foram agregados em

séries temporais de mapas com o percentual de área desmatada acumulada em cada pixel de 28 x 28 km.

6.2.2.4 Preços da soja e do milho

Um dos objetivos deste estudo é estimar os impactos econômicos do desmatamento e da variabilidade climática para a o agronegócio brasileiro. Para isso, utilizamos a série histórica de preços da soja e do milho praticados no mercado internacional nos últimos 60 anos proveniente do banco de dados macroeconômicos *Trading Economics National Statistical* (tradingeconomics.com). Este banco de dados inclui séries de dados que vêm diretamente de fontes oficiais, como bancos centrais e agências de estatística.

6.2.3 Início da estação chuvosa

O início da estação chuvosa foi identificado em cada célula ao longo do tempo através do método *anomalous accumulation* (AA; Equação 6.1; LIEBMANN *et al.*, 2007). Este método foi usado com sucesso por ARVOR *et al.*, 2014 e LEITE-FILHO *et al.*, 2019b para o mesmo fim no estado do Mato Grosso e sul da AM. Nosso ano hidrológico se inicia no mês de agosto, visando identificar com maior precisão a transição do período seco para a estação chuvosa visto que o período de chuvas na região Amazônica e no CE é compreendido em média, entre outubro e março, e o período seco entre maio e setembro (CPTEC/INPE). O AA possui uma aplicação direta para o setor agrícola ao considerar a demanda hídrica de uma planta em desenvolvimento como valor de referência (R_{ref}). O AA (mm.dia^{-1}) é definido por:

$$AA^{(\text{day})} = \sum_{n=1}^{\text{day}} (R_n - R_{ref}) \quad (\text{Equação 6.1})$$

onde R_n é a chuva no dia n e R_{ref} é um valor de chuva de referência, ambos em mm.dia^{-1} . Considerando as aplicações agrícolas deste estudo, o R_{ref} foi fixado em 2.5 mm.dia^{-1} , representativo das necessidades de uma muda de cultivar de soja (ABRAHÃO E COSTA, 2018). A data de início é definida como o dia mínimo de AA. Assim, o início do período é selecionado como o dia a partir do qual AA permanece positivo durante o período mais longo verificado.

6.2.4 Definição dos períodos de cultivo

Para que o sistema DC seja viável, os agricultores precisam garantir que a soja seja colhida precocemente, para que o milho segunda safra amadureça enquanto as condições climáticas são favoráveis. Não obstante, uma das medidas de adaptação à mudança nos padrões climáticos é a postergação ou adiamento do plantio da soja (e conseqüentemente do milho segunda safra). Neste sentido, os produtores de grãos da AM e CE podem postergar ou adiantar o plantio de acordo com as condições climáticas da época. Neste sentido, estimamos os períodos de cultivo da primeira e segunda safras a partir das datas de início da estação chuvosa identificadas no período histórico. Na prática, os dados climáticos diários foram agrupados do início da estação chuvosa (considerado o dia 1) até o 140º dia. Assumimos que grande parte do cultivo e da colheita da soja ocorreram neste período (primeira safra). Na sequência, do 141º dia até o 260º dia (geralmente de janeiro a abril), assumimos ser o período no qual ocorreu o cultivo e colheita do milho segunda safra (segunda safra).

Para isso, assumimos que: (i) O início do plantio é definido pelo início da estação chuvosa; (ii) As cultivares de soja e milho segunda safra plantadas comercialmente no país tem seus ciclos fenológicos de ≈ 120 dias (PIRES *et al.*, 2016); (iii) O tempo entre a colheita da soja e o plantio do milho segunda safra pode levar até 20 dias em uma fazenda de porte médio (PIRES *et al.*, 2016; BRUMATTI; PIRES; SANTOS, 2020); (iv) A operação de colheita da soja (primeira safra) e a semeadura do milho segunda safra (segunda safra) são realizadas concomitantemente (BRUMATTI; PIRES; SANTOS, 2020).

6.2.5 Resíduos climáticos devido ao desmatamento

Através do cálculo dos resíduos climáticos buscamos isolar os efeitos do desmatamento dos efeitos da variabilidade climática. Para isso aplicamos um processo composto por 3 passos (Material suplementar) adaptado de LEITE-FILHO *et al.*, 2021. No passo 1 modelamos a variabilidade climática espacial característica da região de estudo e que poderia adicionar um viés às nossas análises. Foram testados 5 algoritmos de aprendizagem supervisionada de máquinas para modelar a variabilidade espacial do clima: Support Vector Machine, Random Forest, Generalized Linear model e Generalized additive model. Todos os algoritmos receberam a posição geográfica (Latitude – φ e Longitude - λ) e a altitude média de cada célula (ζ) como variáveis. A efetividade dos algoritmos em simular o padrão espacial de cada variável climática foi avaliada através da diferença entre os valores observados e os valores estimados

(viés). Para todas as variáveis estudadas o algoritmo Random Forest (RF) utilizando 1000 árvores apresentou maior similaridade em comparação com os valores médios observados.

No passo 2 calculamos a diferença entre os valores observados em cada ano e os valores modelados pelo algoritmo RF (Passo 1). Assim, removemos as tendências climatológicas devido à localização geográfica e a elevação. Como o clima simulado pelo RF é estático ao longo do tempo, as equações resultantes do segundo passo representam o desvio observado (resíduo) em relação ao padrão climatológico ligado à variabilidade interanual. No passo 3 subtraímos a precipitação média anual para toda a região de estudo dos resultados das equações anteriores visando remover o sinal de fatores de larga escala, como o sinal da ENSO (*El Niño* and the Southern Oscillation), que influenciam o clima na AM e CE.

6.2.6 Quebras e ganhos de safra (Resíduos de produtividade)

Não há atualmente uma definição explícita de quebra de safra e ganhos de safra que permitam quantificar e comparar diferentes eventos. O glossário do Banco Nacional de Desenvolvimento Econômico e Social (BNDES, 2006) define quebra de safra simplesmente como uma “redução significativa do resultado de uma colheita, em decorrência da baixa produção e/ou baixa produtividade”. Neste sentido, os resíduos de produtividade da soja ($R_{soja_{i,j,t}}$) e do milho ($R_{milho_{i,j,t}}$) foram estimados de forma espacialmente explícita utilizando os mapas temporais de produtividade da soja e do milho preparados no item 2.2.3. Para isso, reduzimos a produtividade anual de cada pixel pela média móvel de produtividade dos últimos 3 anos obtida naquele mesmo pixel ($\bar{P}_{i,j,t}$). Estes resíduos são a variação da produtividade observada em cada ano em relação à média móvel das últimas 3 safras (Material Suplementar).

$$R_{i,j,t} = P_{i,j,t} - \bar{P}_{i,j,t} \text{ (Equação 6.2)}$$

$$\text{onde, } \bar{P}_{i,j,t} = \frac{P_{i,j,t-1} + P_{i,j,t-2} + P_{i,j,t-3}}{3}$$

As frustrações na produção agrícola, ou seja, a produtividade abaixo do esperado ($R_{i,j,t} < 0$) são chamadas de “quebras de safra” neste artigo. Ou seja, uma redução do resultado de uma colheita, sendo medida em termos de produtividade, em relação à produtividade esperada para a safra. Por outro lado, o alcance de produtividades mais elevadas em comparação à média móvel de produtividade dos últimos 3 anos ($R_{i,j,t} > 0$) são considerados “ganhos de safra”.

6.2.7 Modelagem espacial da área plantada

Para que fosse possível quantificar os ganhos ou perdas em volume (Toneladas de soja e milho) associados às quebras ou ganhos de produtividade estimados no item 2.6, simulamos a alocação espacial dos cultivos destinados ao sistema DC ao longo da série temporal estudada utilizando o modelo Otimizagro. O Otimizagro é um modelo espacialmente explícito que simula o uso da terra e as mudanças no uso da terra, silvicultura, desmatamento e regeneração sob vários cenários de demanda de terras agrícolas e políticas ambientais brasileiras (ROCHEDO *et al.*, 2018; LEITE-FILHO *et al.*, 2021). O modelo simula nove culturas anuais (incluindo culturas simples e duplas), cinco culturas perenes e florestas plantadas em pixels de 25 ha de resolução espacial.

6.2.8 Determinantes das quebras e ganhos de produtividade

Considerando a importância de se produzir cada vez mais grãos, além da necessidade de se investir em tecnologias inovadoras na produção, faz-se importante conhecer os fatores que podem causar frustrações na produtividade e consequentemente na produção agrícola. Neste sentido, as variáveis espaço-temporais determinantes das alterações de produtividade das lavouras de soja e milho na AM e CE entre 2006 a 2019 foram identificadas utilizando Modelos Espaciais Autorregressivos aplicados aos dados organizados em painel (SAR; HSIAO, 1986; HURLIN, 2005). Os resíduos de produtividade anuais da soja e do milho em cada pixel foram consideradas a variável dependente, ao passo em que as variáveis explicativas foram divididas em 5 grupos (Figura 6.1):

- (1) **Rentabilidade na safra anterior:** O custo de produção referente à safra anterior convertido em rentabilidade. As quebras de safra afetam diretamente a rentabilidade da atividade, pois impacta a receita do produtor, que a depender da sua saúde financeira, pode resultar em menor investimento futuro na atividade e contribuir ainda mais para uma nova quebra de produção, pois além da imprevisibilidade climática, sua cultura estará desprovida da proteção gerada pela adoção das melhores práticas de manejo.;
- (2) **Climatologia:** A média do volume de chuvas, início da estação chuvosa e temperaturas máxima e mínima em cada pixel durante o período estudado;
- (3) **Variabilidade interna do clima:** A média do volume de chuvas, início da estação chuvosa e temperaturas máxima e mínima em anos em que o Oceano Pacífico Equatorial esteve mais quente (*El Niño*) ou mais frio (*La niña*) do que a média normal histórica.

No Brasil, grandes quebras de safras estão, em geral, associadas aos efeitos climáticos adversos dos fenômenos *El Niño* e *La niña* (BERLATO; FONTANA, 2001).

- (4) **Impactos diretos do desmatamento:** Percentual de área desmatada acumulada em cada pixel e em cada ano;
- (5) **Impactos indiretos do desmatamento:** Resíduos do volume de chuvas, início da estação chuvosa e temperaturas máxima e mínima devido ao desmatamento.

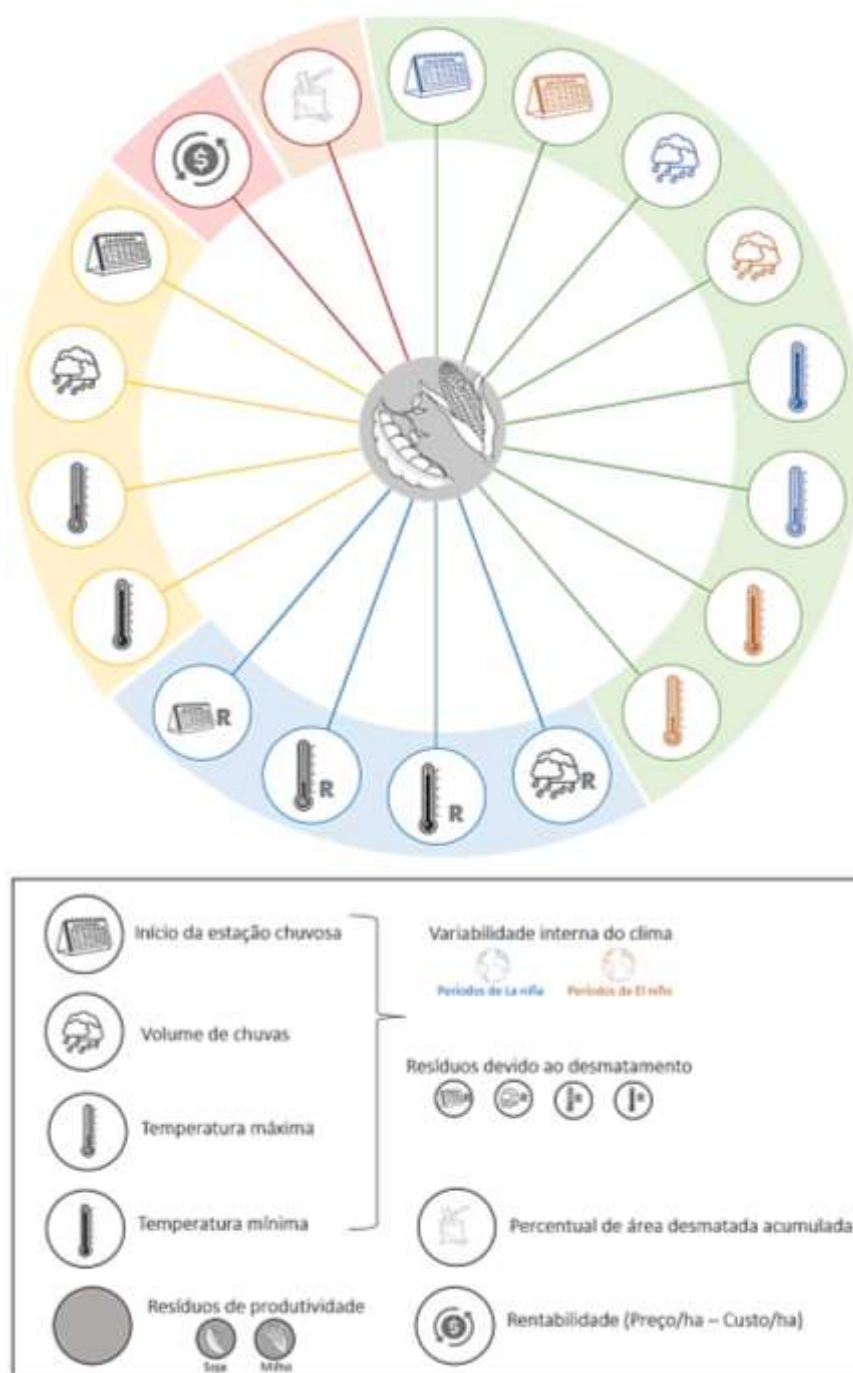


Figura 6.1: Modelo espacial autorregressivo usado para a identificação dos determinantes espaciais que afetam os resíduos de produtividade da soja e do milho nos Biomas AM e CE.

Para escolha do modelo apropriado, do ponto de vista estatístico, buscou-se o modelo mais parcimonioso, isto é, o modelo que envolva o mínimo de parâmetros possíveis a serem estimados e que explique bem o comportamento da variável resposta. Nesta linha, utilizamos o Critério de Informação de Akaike (AIC) para a escolha do melhor modelo. Por fim, aplicamos

o teste de Jackknife (EFRON; STEIN, 1981) aos modelos SAR selecionados para estimarmos a importância relativa do desmatamento (efeito direto e indireto) nos resíduos de produtividade da soja e do milho. Isto foi feito ao compararmos o coeficiente de ajuste (R^2) do modelo completo (incluindo todas as variáveis) com os coeficientes R^2 retirando as variáveis associadas ao desmatamento (percentual de área desmatada acumulada e resíduos climáticos devido ao desmatamento) (Material Suplementar).

6.2.9 Impactos econômicos

Os impactos econômicos ($\$_{i,j,t}$) resultantes foram estimados considerando os ganhos ou perdas em volume ($P_{i,j,t}$, em toneladas). Para isso utilizamos os resíduos de produtividade ($R_{soja_{i,j,t}}$ e $R_{milho_{i,j,t}}$, em toneladas/hectare), a área plantada em cada pixel ($A_{i,j,t}$, em hectares), em hectares e as cotações dos preços dos grãos (US\$ saca 60kg) durante a série histórica (tradieconomicos.com) (Equações 6.3 e 6.4).

$$P_{i,j,t} = R_{i,j,t} \times A_{i,j,t} \quad (\text{Equação 6.3})$$

$$\$_{i,j,t} = \frac{P_{i,j,t} \times 1000}{60} \times \text{US\$ saca 60kg} \quad (\text{Equação 6.4})$$

Todos os valores monetários foram corrigidos (deflacionados ou inflacionados) considerando a inflação norte-americana quando os preços estavam em dólares (US\$) e considerando a inflação brasileira quando os dados estavam em reais (R\$). Isso nos permitiu comparar os valores em diferentes momentos do tempo para saber se aquele valor aumentou ou diminuiu em termos reais.

6.3 RESULTADOS E DISCUSSÃO

6.3.1 Ameaças climáticas

Ao aplicarmos o teste de mann-kendall (SNEYERS, 1975) às séries climáticas anuais de precipitação e temperatura provenientes do ERA5 nas últimas 4 décadas, nossos resultados indicam que os padrões pluviométricos (sazonalidade e volume das chuvas) e os padrões de temperatura (máxima e mínima) na AM e CE apresentam tendência de mudança. Isto é, são consideradas séries não-estacionárias, constituindo um forte indicativo de marcantes mudanças climáticas locais e regionais em curso. Mesmo que as quebras de safra muitas vezes estejam sendo apresentadas como ocorrendo dentro da sua variabilidade natural (fruto do *El Niño*)

ou de alguma outra dinâmica que se tenta explicar, estes resultados reforçam que o clima na AM e CE não está dentro da sua variabilidade normal.

6.3.1.1 Atraso no início da estação chuvosa

Tanto na AM quanto no CE as chuvas vêm começando mais tarde a cada ano (Figura 6.2). Na AM a estação chuvosa tem se estabelecido com um atraso médio de 1.2 dias/ano, acumulando um atraso de ≈ 1 mês e 18 dias desde 1980 (Figura 6.2a). No CE a estação tem começado em média, 1.4 dias mais tarde a cada ano, acumulando um atraso de ≈ 1 mês e 26 dias (Figura 6.2b). Para as cultivares de soja comerciais mais plantadas na AM e CE (cultivares de soja resistentes ao glifosato), a semeadura deve acontecer na época em que a água armazenada no solo possa ser encontrada em quantidade suficiente para a germinação e emergência das plântulas. Conseqüentemente as janelas de cultivo da primeira e segunda safras também se alteraram proporcionalmente ao estabelecimento tardio do período de chuvas.




Figura 6.2: Médias das datas de início da estação chuvosa nos Biomas (a) Amazônia e (b) Cerrado entre 1980 a 2020. A tendência de atraso no estabelecimento da estação chuvosa é estatisticamente significativa na AM e no CE (Teste de mann-kendall; $p < 0.05$).

Em 1980, a soja era plantada na segunda quinzena de setembro na AM (em média no dia 21) e conseqüentemente colhida na segunda quinzena de janeiro (por volta do dia 20). Na seqüência o milho era semeado, e após 120 dias era colhido (na segunda quinzena de maio). Em 2019, em média a semeadura aconteceu na primeira quinzena de outubro (por volta dia 11 de outubro), levando ao atraso no plantio do milho (que só ocorreu por volta do dia 10 de fevereiro). No CE, a soja era plantada, em média, na primeira semana de setembro (por volta

do dia 7) 1980 e conseqüentemente colhida na primeira semana de janeiro (por volta do dia 6). Neste período o milho era semeado e cultivado, sendo colhido na primeira semana de maio (por volta dia 6 de maio). Entretanto, em 2020, a semeadura da soja, aconteceu na última semana de outubro (em média no dia 30), em efeito cascata o milho no CE só foi semeado, em média, nos primeiros dias de março.

6.3.1.2 Redução no volume de chuvas

Além do atraso no início da semeadura, as tendências observadas também apontam quedas estatisticamente significativas no volume de chuvas em ambos os biomas ($p < 0.05$; Figura 6.3a,b). Estes resultados corroboram com as tendências de uma AM (GATTI *et al.*, 2020) e Centro-Oeste brasileiro mais secos reportadas na literatura (PIRES *et al.*, 2016). O volume anual de chuvas vem diminuindo ≈ 180 mm/década na AM (Figura 6.3a) e ≈ 100 mm/década no CE (Figura 6.3b). Isto significa uma redução média de $\approx 10\%$ /ano no volume de chuvas na AM e $\approx 9\%$ /ano no CE. Nas últimas 3 décadas a redução acumulada média chega a $\approx 30\%$ em ambos os biomas.

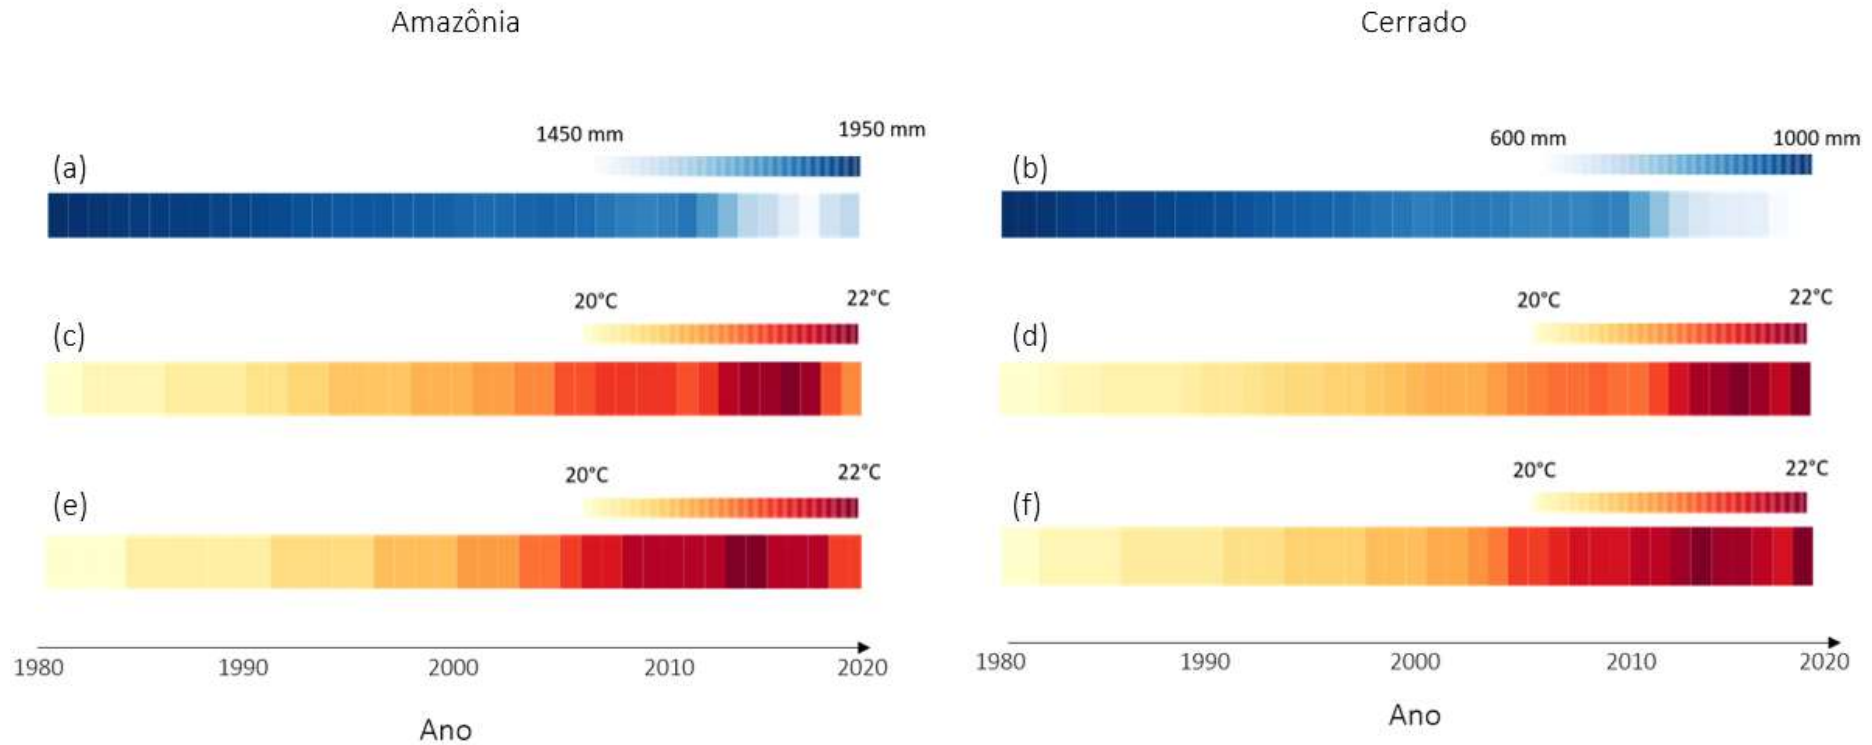


Figura 6.3: Tendências climáticas entre 1980 e 2020. Média do volume de chuvas nos Biomas (a) Amazônia e (b) Cerrado. Média da Temperatura máxima na (a) Amazônia e (b) Cerrado. Média da temperatura mínima na (e) Amazônia e (f) Cerrado. Todas as tendências de redução no volume de chuvas e aquecimento são estatisticamente significativas segundo o teste de mann-kendall ($p < 0.05$; Material Suplementar).

6.3.1.3 Aquecimento do ar

Além de um CE e AM mais secos, nossas análises apontam tendências de aquecimento do ar estatisticamente significativas ($p < 0.05$; Teste de Mann-Kendall) em ambos os biomas (Figura 6.3c-f), corroborando com o aquecimento apontado na literatura (SIMMONS *et al.*, 2017; SCHWINGSHACKL *et al.*, 2018). Em média, a temperatura máxima na AM está 1.5°C mais quente em comparação à década de 1980, passando de 30.5°C para 32°C (Figura 6.3c). A média das temperaturas mínimas por sua vez se aqueceram 1°C (Figura 6.3e), passando de 20.5°C em 1999 para 21.5°C em 2019. O aquecimento é ainda mais expressivo no CE, onde as temperaturas mínimas e máximas aumentaram, em média, $\approx 2.5^{\circ}\text{C}$ e 1.5°C desde 1999 (Figura 6.3d, f). A temperatura máxima média no CE passou de 30°C para 32.5°C ($+2.5^{\circ}\text{C}$; Figura 6.3d). Já a temperatura mínima média passou de 20°C para 21.5°C no mesmo período ($+1.5^{\circ}\text{C}$; Figura 6.3f).

6.3.2 Evolução da área plantada e da produtividade da soja e do milho

A tendência tem sido de crescimento sistemático da produção de grãos na AM e CE nos últimos anos. Entre 2003 e 2019 a produção da soja na AM cresceu 77%, já a produção do milho cresceu 82%. No CE a produção da soja cresceu 61% e a produção do milho cresceu 70% no mesmo período. Ambas as taxas superam a média de crescimento global (FAO, 2021). Grande parte desta produção está atrelada a dois fatores principais: a expansão da área plantada (seção 6.3.2.1) e a intensificação dos cultivos (seção 6.3.2.2).

6.3.2.1 Expansão da área plantada

A área destinada ao sistema DC dobrou no CE e mais que triplicou na AM entre 2006 e 2019 (Figura 6.4). O avanço se deu, dentre outros motivos, devido às melhorias na correção do solo e cultivares adaptadas para o CE e, posteriormente, para a AM, conquistando enormes quantidades de terras mecanizáveis para a produção. A área plantada na AM passou de 1.3 para 4.3 milhões de hectares ($+3$ milhões de hectares). No CE o incremento foi de 7.1 milhões de hectares, um salto de 7 para 14.1 milhões de hectares. A área plantada no País não só vem crescendo em área, como vem atingindo locais até pouco ou nada desmatados. Em ambos os Biomas o crescimento foi caracterizado pela ocupação de novas áreas, sobretudo por meio da ocupação agrícola do MATOPIBA onde a área cultivada aumentou significativamente nas últimas duas décadas, de 600 mil hectares para 5 milhões de hectares.

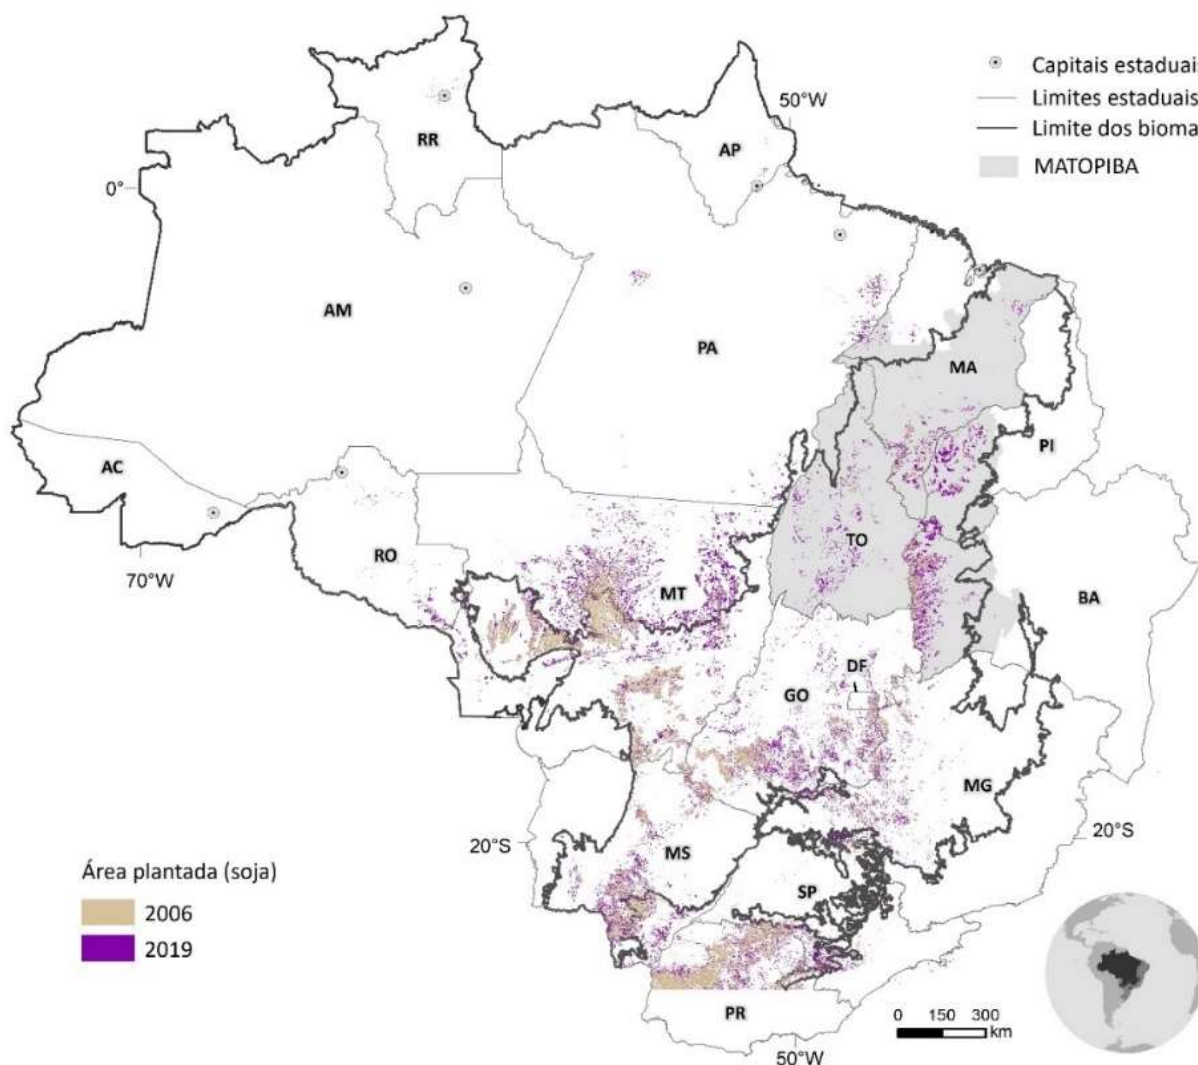


Figura 6.4: Expansão da área agrícola destinada ao sistema DC soja-milho entre 2006 e 2019 nos Biomas Amazônia e Cerrado. Destaca-se a ampla expansão principalmente no norte do estado do MT e no MATOPIBA.

6.3.2.2 Intensificação dos cultivos

A produtividade média da soja colhida na AM passou de 2595.5 kg/ha no início década de 2000 para 3233.4 kg/ha em 2019, um incremento de 20% em duas décadas (+49.1 ton/ha a cada ano). No CE a produtividade média da soja passou de 2427.9 kg/ha para 3094.6 kg/ha no mesmo período (+22%), um incremento médio de 51.3 ton/ha/ano. Na segunda safra, a produtividade média do milho cultivado na AM passou de 2769.1 kg/ha no início década de 2000 para 4365.5 kg/ha em 2019 (+122.8 ton milho/ha/ano). No CE a produtividade média passou de 3416.6 kg de milho por hectare para 5620.7 kg/ha entre 2006 e 2019 (+169.5

ton/ha/ano). Em média, a produtividade do milho segunda safra cresceu $\approx 37\%$ na AM e 39% no CE durante os 13 anos estudados. A produtividade do milho apresenta incrementos de produtividade mais expressivos quando comparados à soja em ambos os biomas.

6.3.2.3 Extensificação vs expansão

Apesar dos investimentos em tecnologia nos últimos anos, o crescimento da produção ocorreu principalmente pela incorporação de novas áreas ao processo produtivo. Enquanto a área destinada ao sistema DC na AM cresceu 71% entre 1999 e 2019, a produtividade da soja e do milho segunda safra, cresceram 20% e 37% , respectivamente (Figura 6.5). Neste mesmo período, a produção da soja passou de 3.2 para 13.8 milhões de toneladas ($+77\%$) e a produção do milho saltou de 3.4 para 18.7 milhões de toneladas ($+82\%$). Ou seja, o incremento de mais de 10.6 milhões de toneladas de soja produzidos na AM se devem em grande parte à expansão (78%) e em menor parte ao incremento de produtividade (22%). Embora o aumento de mais de 15.2 milhões de toneladas de milho produzidos na AM também estejam ligados em grande parte à expansão dos cultivos (60% ; figura 6.5), o incremento de produtividade tem um maior efeito no aumento da produção do milho segunda safra.

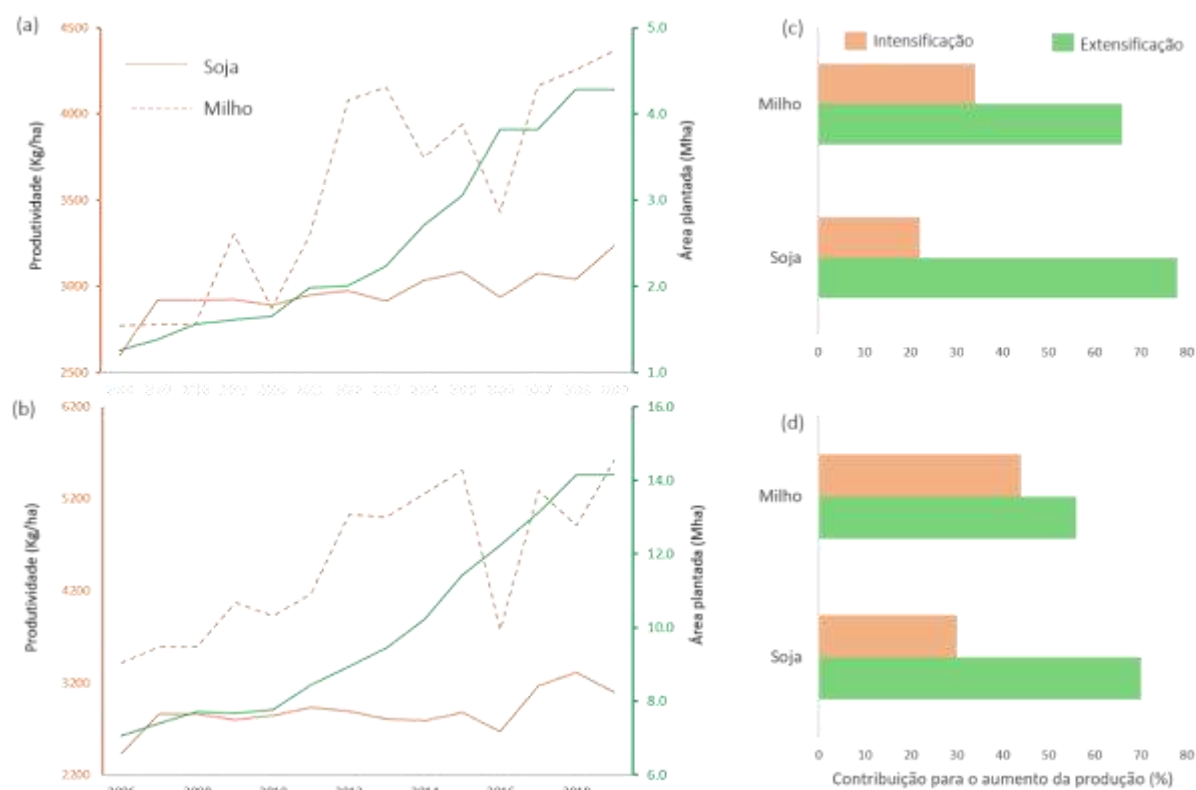


Figura 6.5: Aumento da produção de soja e milho através da intensificação e extensificação na (a) Amazônia e (b) Cerrado.

Já no CE a área destinada ao sistema DC cresceu 50% entre 2006 e 2019 e a produtividade da soja e do milho segunda safra, cresceram 22% e 39%, respectivamente. Neste mesmo período, a produção da soja passou de 17.1 para 43.8 milhões de toneladas (+61%) e a produção do milho saltou de 24.1 para 79.5 milhões de toneladas (+70%). Isso nos leva a inferir que o incremento de mais de 55.4 milhões de toneladas de soja colhidos na AM se deve em grande parte à expansão (70%) e em menor parte ao incremento de produtividade lastreado pelo avanço tecnológico (30%). Embora o incremento de mais de 55.5 milhões de toneladas de milho produzidos no CE também estejam ligados em grande parte à expansão (56%), a produtividade tem um maior efeito no aumento da produção do milho (44%) em comparação à soja. Portanto, mesmo que a intensificação através do aumento de produtividade e da modernização das técnicas agrícolas tenham contribuído fortemente para tornar o Brasil um grande produtor e exportador de grãos, a expansão tem sido a principal via de crescimento da produção de soja e milho.

6.3.3 Aumento das quebras de safra

Embora a produtividade média da soja e do milho venham crescendo nos biomas como um todo, a intensificação não ocorre de forma generalizada no espaço. Os incrementos de produtividade demonstrados na seção 3.4 são uma média para os biomas como um todo. Enquanto algumas regiões experimentam incremento constante, outras contabilizam quebras de produtividade (e consequentemente redução na produção) mais frequentes. Portanto, não é possível generalizar que o crescimento expressivo nos últimos anos reflita por si só a realidade da maioria dos produtores.

Entre 2003 e 2019, as quebras de produtividade da soja mais expressivas aconteceram nos estados do Mato Grosso do Sul (3º maior produtor de soja do país) e Goiás (Responsável por 12,5% da produção nacional de milho e 10,4% da produção de soja) e em outras regiões com grande relevância na produção nacional, como no sudeste dos estados de São Paulo, região central do estado do Mato Grosso e em parte do MATOPIBA (principalmente na região centro-sul do estado de Tocantins) (Figura 6.6a). Por outro lado, os maiores incrementos médios em produtividade da soja são verificados no sudeste de Goiás, nos estados de Tocantins e Piauí e na região centro-sul do Mato Grosso. Na segunda safra as quebras de produtividade são mais expressivas e recorrentes nos estados do MATOPIBA, bem como nas regiões Noroeste dos estados de Goiás e Minas Gerais e no Norte de Rondônia (Figura 6.6b). Já os ganhos médios para o milho são expressivos para os cultivos da porção oeste do CE, principalmente no sudoeste do estado do Mato Grosso e nas regiões sul dos estados de Goiás e Mato Grosso do Sul (Figura 6.6b).

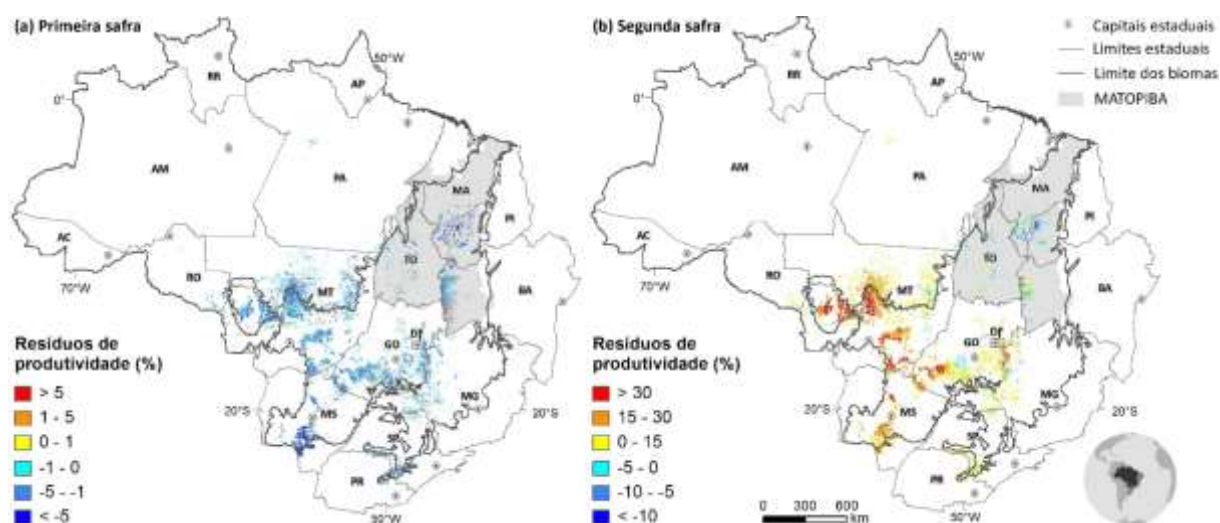


Figura 6.6: Média dos resíduos de produtividade (%) entre 2006 e 2019 nos Biomas Amazônia e Cerrado para (a) Primeira safra (soja) e (b) Segunda safra (milho).

As quebras de produtividade da soja colhida na AM chegaram a -9%, ao passo em que os ganhos máximos chegaram +4%. No CE, as quebras médias da soja alcançaram -12%, e os ganhos máximos chegaram a +10%. Ou seja, apesar da AM e do CE como um todo verificarem um aumento de produtividade da soja, algumas regiões tem sofrido mais quebras do que ganhos. Na segunda safra a situação se inverte. As quebras de produtividade do milho chegaram a -9% na AM, ao passo em que os ganhos máximos alcançaram 34%. No CE, as quebras na segunda safra chegaram a -15%, ao passo em que os ganhos máximos ultrapassaram 46%. Ou seja, diferentemente do que vem acontecendo com a soja, os ganhos em produtividade do milho superam as perdas médias.

Embora a produtividade média da soja e do milho tenham crescido 20% e 37% na AM como um todo, respectivamente, resíduos de produtividade negativos estão se tornando mais frequentes e atingem um maior número de regiões nos anos mais recentes tanto na AM quanto no CE (Figura 6.7). No CE como um todo, a produtividade média da soja e do milho segunda safra cresceu 20% e 37%, respectivamente. Entretanto, as funções de distribuição dos resíduos de produtividade apontam quebras de produtividade da soja e do milho mais frequentes e em mais regiões nos anos mais recentes (Ou seja, as curvas de distribuição dos resíduos de produtividade da soja e do milho demonstram um deslocamento das curvas em direção aos resíduos negativos (em vermelho), indicando que mais lavouras têm experimentado frustrações na produtividade de soja e milho de forma mais frequente na AM e CE.

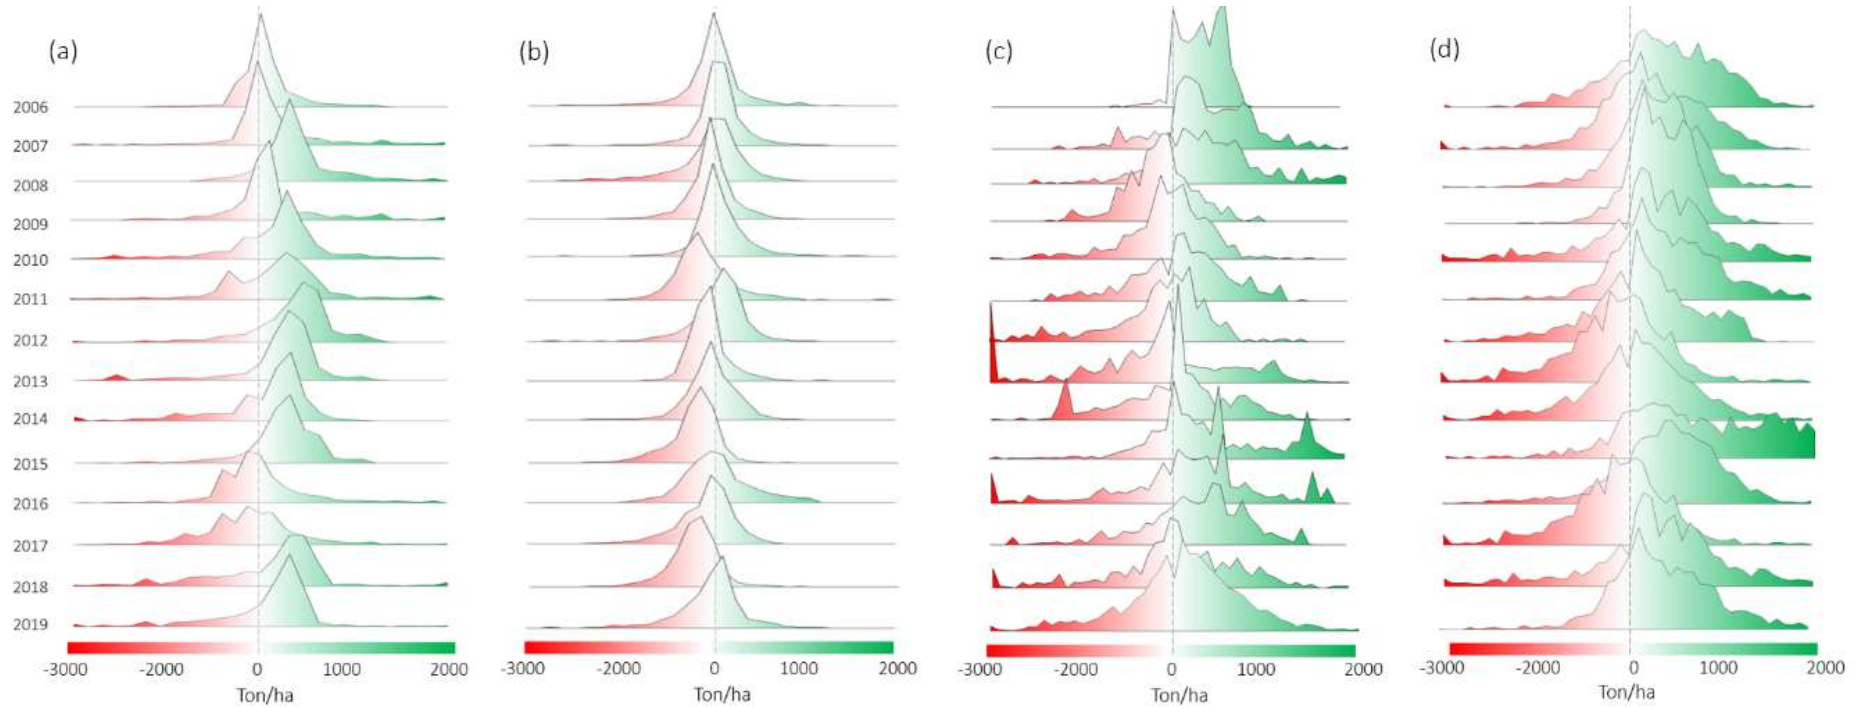


Figura 6.7: Funções de distribuição dos resíduos de produtividade para a (a) Primeira Safra Amazônia; (b) Primeira Safra Cerrado; (c) Segunda Safra Amazônia e (d) Segunda safra Cerrado.

6.3.4 Determinantes espaciais das variações de produtividade

6.3.4.1 Primeira safra

Os resultados do modelo espacial autorregressivo selecionado para a AM ($r^2 = 0.69$; $p < 6 \times 10^{-3}$; AIC = 1199.5; Tabela Suplementar 6.1) demonstram que a produtividade da soja é dependente da rentabilidade dos agricultores na safra anterior, do volume e sazonalidade das chuvas (climatologia), bem como sensível à variabilidade interna na sazonalidade e volume das chuvas (Volume e início das chuvas nos anos de *El niño* e *La niña*). As quebras na safra anterior afetam negativamente a rentabilidade da atividade, pois impacta a receita do produtor, que a depender da sua saúde financeira, pode resultar em menor investimento futuro na atividade e contribuir ainda mais para uma nova quebra de produção, pois além da imprevisibilidade climática, sua cultura estará desprovida da proteção gerada pela adoção das melhores práticas de manejo.

O início da estação chuvosa mais tardio, por sua vez aumenta a produtividade da soja, visto que o proprietário pode esperar o cenário climático mais seguro para implementar sua lavoura, o que, provavelmente, impactará na segunda safra (discutido posteriormente). Entretanto, o início da estação chuvosa nos anos de *El niño* tendem a reduzir a produtividade da soja, ao passo em que os anos de *La niña* tendem a aumentá-la. Há de se ressaltar também um maior volume de chuvas (climatologia) associado a maiores produtividades, ao passo em que nos anos de *El niño* a produtividade tende a reduzir em consequência do menor volume de chuvas na AM. Já que o fenômeno *La niña* é capaz de potencializar as chuvas nas regiões Norte e Nordeste, levando a maiores patamares de produtividade. Os determinantes espaciais das variações de produtividade da soja plantada na AM de maior peso estão atrelados ao desmatamento. Além dos determinantes citados, a área desmatada acumulada afeta direta e indiretamente os rendimentos de soja produzidos no Bioma. De forma indireta, menores resíduos do volume de chuvas causados pelo desmatamento (isto é, menor volume de chuvas acumulado) estão associados à menores valores de produtividade.

A necessidade hídrica da soja para obtenção de máximo rendimento está entre 450 e 800 milímetros por ciclo de cultivo, dependendo das condições climáticas, do manejo da cultura e da duração do ciclo. A semente de soja precisa absorver, no mínimo, 50% de seu peso em água. Nessa fase, o conteúdo de água no solo não deve exceder a 85% do total de água disponível e nem ser inferior a 50%. Na fase de germinação-emergência, tanto o excesso quanto o déficit de

água são prejudiciais à obtenção de uma boa uniformidade na população de plantas. Déficits hídricos expressivos, durante a floração e o enchimento de grãos, provocam alterações fisiológicas na planta, como o fechamento estomático e o enrolamento de folhas e, como consequência, causam a queda prematura de folhas e de flores e abortamento de vagens, resultando, por fim, em redução do rendimento de grãos (EMBRAPA, 2008).

De forma direta, o aumento na área desmatada acumulada reduz a produtividade de soja na escala geográfica analisada. Isto pode acontecer devido à diversos fatores: Erosão do solo, deslizamentos de terra, desertificação, extinção de fontes de água e proliferação de insetos praga. O desmatamento causa erosão e desertificação dos solos através do desgaste do solo a partir da remoção de suas camadas superficiais. Ela pode ser provocada pela chuva, pela água dos rios, pelo vento e até pelo gelo. Com o desmatamento, retira-se a cobertura natural da terra, que funciona como barreira. No solo exposto esse processo ocorre mais intensamente. Além disso, o impacto da água no solo pode provocar mudanças em sua consistência e, em terrenos acidentados, gerar grandes deslizamentos de terra. Nos casos em que o solo permanece exposto por um longo período, pode ocorrer a perda total de sua camada fértil, tornando a área completamente improdutiva. Esse processo é chamado de desertificação. E, quando isso ocorre, pode-se considerar que a área não possui mais utilidade para a agricultura. De forma direta o desmatamento pode ainda extinguir fontes de água o que pode afetar diretamente a produção agrícola. É preciso se tomar cuidado com a remoção de espécies florestais e vegetações próximas as nascentes, pois, a abertura dessas áreas pode provocara eliminação dessas nascentes de água. Podendo, conseqüentemente, acabar eliminando também esses cursos d'água.

Ainda, o efeito direto do desmatamento pode levar à escassez de habitats naturais de muitas espécies, contribuindo para a morte de muitos animais e o desaparecimento de alguns grupos. Isso traz problemas para a cadeia alimentar e pode acarretar problemas para as lavouras. Esses problemas surgem porque a vegetação é um local de refúgio de muitos inimigos naturais de insetos que podem ajudar no controle natural de insetos-praga. Com a retirada dessas áreas florestais, reduz-se grandemente a biodiversidade do local, acabando com alguns grupos de inimigos naturais e tornando a soja e o milho muito mais susceptíveis ao ataque de pragas e doenças. Outro ponto a ser analisado é que essas áreas de vegetação também podem ser o habitat de muitos insetos polinizadores, que são de grande importância para muitas culturas agrícolas.

Já no CE a produtividade da soja também é afetada pela rentabilidade na safra anterior, bem como pela sazonalidade das chuvas nos anos de El nino ($r^2 = 0.79$, $p = 2.2 \times 10^{-16}$, AIC = 3172.4; Tabela Suplementar 6.3). Entretanto, novamente destacamos os impactos do desmatamento ao modificar o volume de chuvas, os padrões de temperatura máxima e o início da estação chuvosa (ou seja, os resíduos climáticos devido ao desmatamento). O aquecimento tem efeito adverso na taxa de crescimento do milho pois provoca distúrbios na floração e diminuem a capacidade de retenção de vagens da soja, problemas que se acentuam com a ocorrência de déficits hídricos. Ou seja, um CE mais quente e mais seco intensificados pelo desmatamento levam à menores rendimentos da soja já que podem causar déficit hídrico da germinação ao desenvolvimento da plântula de soja e milho causando diminuição do rendimento (A produtividade cai 5% a cada dia com temperatura acima de 30°C; FLACH *et al.*, 2021). Não obstante, o encurtamento do ciclo de desenvolvimento causados pelo atraso no estabelecimento da estação chuvosa em cenários com aumentos sinérgicos de temperatura são os fatores de maior peso na determinação da produção da soja brasileira (SIQUEIRA *et al.*, 2000; SIQUEIRA *et al.*, 2001).

6.3.4.1 Segunda safra

A produtividade do milho na AM é particularmente sensível aos padrões de temperatura máxima e mínima ($r^2 = 0.83$; $p < 0.05$; Tabela Suplementar 6.5). Tanto o aumento na temperatura máxima quanto mínima tendem a aumentar a produtividade do milho colhido no Bioma. Além disso, o aumento da temperatura nos anos de *La nina* tende a aumentar a produtividade da soja na AM, em sinergia com as mudanças na sazonalidade da estação chuvosa nos anos de *La nina*. Entretanto, ao desequilibrar as relações biosfera-atmosfera e induzir a mudanças biofísicas, o desmatamento aumenta as temperaturas levando a redução dos rendimentos do milho colhido tanto na AM quanto no CE. Similar ao demonstrado para a soja na AM e CE, o estado de conservação florestal é um dos principais fatores causais das variações de produtividade do milho em ambos os biomas. Similarmente à primeira safra, desmatamento reduz a produtividade do milho de forma direta (o aumento percentual na área desmatada acumulada diminui de forma direta a produtividade) e de forma indireta, ao induzir mudanças no balanço de energia e no saldo de radiação à superfície que provocam uma ascensão dos padrões de temperatura máxima e mínima.

Já no CE a produtividade do milho tende a aumentar com o aumento da rentabilidade da safra anterior, ao mesmo tempo em maiores valores de produtividade estão associados à maiores volumes de chuva e ao início da estação chuvosa mais cedo que ocorrem nos anos de *La nina* ($r^2 = 0.76$, $p = 2.2 \times 10^{-16}$, AIC = 4516.8; Tabela Suplementar 6.7). Por outro lado, menores valores de produtividade do milho são causados pelo aquecimento das temperaturas máximas tanto na climatologia e principalmente nos anos de *El nino* (Anos nos quais já se esperam temperaturas mais altas e condições mais quentes). A primeira linha de defesa da planta de milho diante do aumento das temperaturas e da seca é o fechamento dos estômatos que, por sua vez, causam a diminuição da absorção de CO₂ e, conseqüentemente, das taxas fotossintéticas. Menos fotossíntese implica em biomassa comprometida e menor produção de grãos. O aumento das temperaturas e a seca são críticos principalmente em duas fases da cultura do milho: no florescimento e no enchimento de grãos. No florescimento a seca pode causar problemas na polinização dos grãos, resultando espigas falhadas e, conseqüentemente, em menor produção. Outro período crítico é do enchimento de grãos. Neste período a atividade metabólica das plantas é intensa. Há uma grande demanda dos fotoassimilados por carboidratos que serão deslocados para encher os grãos.

6.3.5 Perdas agrícolas potenciais e impactos associados

As quebras de safra fizeram com que 1.3 milhões de toneladas de soja e 1 milhão de toneladas de milho deixaram de ser colhidas na AM entre 2003 e 2019, totalizando mais de 2.3 milhões de toneladas de grãos perdidos. No CE, ≈ 10.2 milhões de toneladas de milho deixaram de ser produzidas, número que chega a 16.3 milhões de toneladas de soja. No total, os agricultores do CE deixaram de produzir mais de 20.5 milhões de toneladas. No total, o Brasil deixou de produzir 23 milhões de toneladas de grãos (Figura 6.8). O aumento das quebras reflete diretamente na renda dos produtores e conseqüentemente na economia nacional. Ainda, a importância do agronegócio brasileiro na esfera global depende dos bons resultados das colheitas de soja e milho na AM e CE. Nos anos de menor colheita as exportações são diretamente afetadas e a balança comercial se desequilibra, afetando o sistema de produção de alimentos no mundo, principalmente a produção de proteína animal.




Figura 6.8: Média dos resíduos de produtividade (%) entre 2006 e 2019 nos Biomas AM e CE para (a) Primeira safra (soja) e (b) Segunda safra (milho).

6.3.6 Impactos econômicos potenciais e na receita atingida com as exportações

A produção perdida levou a AM a perdas econômicas potenciais de US\$ \approx 6.2 bilhões na primeira safra, ao passo em que as perdas para a segunda safra ultrapassam US\$ \approx 2.3 milhões (Figura 6.9). Entre 2006 e 2019 o sistema DC na AM perdeu mais de US\$ 8.5 bilhões neste período, o equivalente a \approx US\$ 602.8 milhões por ano. No CE as perdas acarretaram um prejuízo estimado de US\$ \approx 15.4 Bilhões devido às quebras da soja US\$ \approx 8.4 Bilhões devido às quebras do milho causadas pela redução na produtividade das lavouras. No total, o CE perdeu mais de US\$ \approx 23.8 bilhões. Em média o sistema DC praticado no CE vem perdendo \approx US\$ 1.7 bilhões por ano. A nível nacional, as perdas econômicas da soja (Perdas AM + Perdas CE) alcançam US\$ \approx 21.6 bilhões na primeira safra e 10.7 bilhões na segunda safra. Estes valores representam \approx 9% e \approx 7% da produção brasileira de soja e milho colhida no mesmo período.

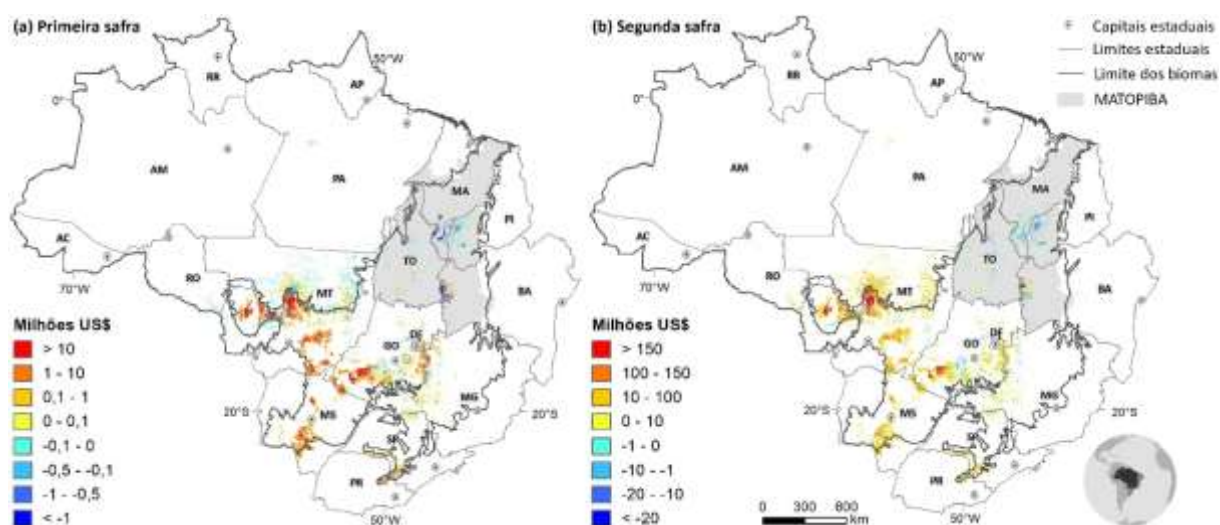


Figura 6.9: Média das perdas e ganhos econômicos (US\$) entre 2006 e 2019 nos Biomas Amazônia e Cerrado para (a) Primeira safra (soja) e (b) Segunda safra (milho).

Entre 2003 e 2019, $\approx 25\%$ da produção de milho brasileira foi destinada para o mercado externo (ABIMILHO, 2021) ao passo que 60% da produção de soja foi exportada (SINDIRAÇÕES, 2021). Considerando estas proporções e levando em consideração as perdas agrícolas associadas às quebras de safra estimadas anteriormente, o agronegócio da AM deixou de exportar 800 mil toneladas de soja e 300 mil toneladas de milho entre 2006 e 2019, acumulando 1.1 milhões de toneladas de grãos não exportados devido às quebras de safra. Os agricultores do CE por sua vez deixaram de exportar 9.8 milhões de toneladas de soja e 2.6 milhões de toneladas de milho, acumulando perdas de US\$ ≈ 4.3 bilhões com a perda de receita não exportadas quebras de ≈ 12.4 milhões de toneladas de grãos não exportados. Os mercados mais afetados são, obviamente o europeu e o chinês, os maiores compradores da soja brasileira (IBGE, 2021). Durante os 14 anos estudados, as quebras de safra na AM e CE levaram à uma redução de $\approx 10\%$ das exportações de soja e milho brasileiras.

6.3.7 Perdas agrícolas e impactos associados ao desmatamento

As variáveis associadas ao desmatamento explicam 9% e 5% das variações na produtividade da soja na AM e CE, ao passo em que representam, 3% e 5% das variações na produtividade do milho, respectivamente. Diante destas estimativas, de posse das perdas agrícolas associadas à redução da produtividade da soja e do milho é possível inferir que, dos US\$ 6,2 bilhões perdidos entre 2003 e 2019 para a soja colhida na AM devido às quebras de safra, US\$ 382,7 milhões se devem ao efeito direto ou indireto do desmatamento e, portanto, poderiam ter sido evitados e mitigados através da conservação florestal. Para o milho colhido

na AM, U\$\$ 5,5 milhões se devem ao efeito do desmatamento. Portanto, em média, o desmatamento da AM gera perdas econômicas de U\$\$ 27,7 milhões por ano aos agricultores que praticam o sistema DC na região. Já no CE, dos U\$\$ 15,4 bilhões potencialmente perdidos entre 1999 e 2019 devido às quebras de safra de soja, U\$\$ 606,6 milhões se devem ao efeito direto ou indireto do desmatamento e, portanto, poderiam ter sido evitados e mitigados através da conservação florestal. Para o milho colhido no CE, dos U\$\$ 8,4 bilhões perdidos entre 1999 e 2019 no cultivo devido às quebras de safra de soja, U\$\$ 318,9 milhões se devem ao efeito do desmatamento. Em média, o desmatamento do CE gera perdas econômicas de U\$\$ 66,1 milhões por ano aos agricultores que praticam o sistema DC na região. A nível nacional, o Brasil perdeu mais de U\$\$ 32,2 bilhões devido às quebras de safra, o que equivale a perdas potenciais de 2,3 bilhões por ano. O Desmatamento por sua vez está ligado à perdas potenciais de 1,3 bilhões entre 2006 e 2016 para o sistema DC (U\$\$ 93,8 milhões por ano).

6.4 CONCLUSÃO

O mundo nunca comprou tantas commodities agrícolas do Brasil como agora e ao longo das próximas décadas este mercado tende a aumentar. Entretanto, a potência da agricultura brasileira foi obtida em grande parte pela sua capacidade de colher duas ou até três safras, rotacionando culturas na mesma terra dadas as boas condições climáticas. Entretanto, a variabilidade climática e o desmatamento vêm minando essa vantagem competitiva no CE e na AM. Considerando que os cultivos da região são em grande parte direcionados à exportação, a ausência de conservação florestal pode afetar as exportações de grãos brasileiros. Conseqüentemente, pode levar a economia brasileira a um estado de completa anomia, visto a dependência proeminente da balança comercial brasileira em relação à exportação de produtos primários. Embora as estratégias de adaptação possam aliviar alguns desses impactos, a manutenção da vegetação nativa é parte crítica da solução para a estabilização do clima local e regional e conseqüentemente da produção agrícola. Embora os dados oficiais brasileiros reforcem que o rendimento e a produção das culturas cresceram desde meados da década de 1980, os ganhos em produtividade e conseqüentemente a produção de soja e milho teriam sido maiores sem os efeitos adversos do desmatamento.

Ao desmatar para produzir, o agronegócio contribui para as mudanças climáticas locais, regionais e globais e assim, coloca em risco a capacidade e os limites da sua própria natureza, já que o clima da qual depende se torna cada vez mais inóspito. Sem a floresta as chuvas e a

regulação térmica se enfraquecem, e na falta de um clima favorável, sobram prejuízos. A escolha não é entre a preservação ou o desenvolvimento agrícola do País, mas entre um agronegócio resiliente e promissor ou um agronegócio climaticamente susceptível que refletirá na economia nacional e no mercado agrícola internacional. Por isso, o Brasil precisa retornar ao caminho da integração entre a produção agrícola sustentável e a conservação ambiental, diminuindo o ímpeto pela abertura novas áreas agrícolas em substituição às formações naturais.

6.5 MATERIAL SUPLEMENTAR

6.5.1 Produtividade agrícola

A partir das informações disponíveis da Pesquisa de Produção Agrícola Municipal fornecidas pelo Instituto Brasileiro de Geografia e Estatística (PAM/IBGE, 2021) obtivemos a produtividade média das lavouras de dupla safra (soja seguida do milho segunda safra, em kg/ha) por município entre 2003 e 2019. Os dados tabulares foram convertidos em mapas de séries temporais com pixels de 28 x 28 km utilizando como método de interpolação a krigagem ordinária (Equação Suplementar 6.1). Essa técnica interpola os valores sem tendenciosidade e com desvios mínimos em relação aos valores conhecidos considerando a estrutura da variabilidade espacial dos dados amostrados (GREGO; VIEIRA, 2005).

$$\hat{Z}_i = \sum_{i=1}^n \lambda_i * Z_i \quad (\text{Equação Suplementar 6.1})$$

em que: \hat{Z}_i é o valor interpolado; λ_i é o peso atribuídos aos valores amostrados; Z_i é o valor do atributo amostrado e n é o número de localidades vizinhas empregadas para interpolação do ponto, sendo que o somatório dos pesos deve ser igual a um.

Nossas análises são focadas na produtividade agrícola visto que, embora os cultivos continuem se expandindo, a Companhia Nacional de Abastecimento do Brasil espera que a produtividade seja um dos principais fatores impulsionando o crescimento da produção no futuro (CONAB, 2019). Também é importante ressaltar que, nas últimas duas décadas a produção brasileira de milho cresceu rapidamente (IBGE, 2021). Entretanto, a área do milho primeira safra caiu 51% e a do milho segunda safra cresceu 6x. Atualmente $\approx 70\%$ da produção nacional de milho corresponde ao milho de segunda safra de sequeiro cultivado extemporaneamente depois da soja precoce (CONAB, 2021);

Focamos na produtividade do binômio soja-milho devido a dois pontos principais: (i) A Companhia Nacional de Abastecimento do Brasil espera que a produtividade seja o principal fator impulsionando o crescimento da produção nas próximas duas décadas (CONAB, 2019); (ii) Nas últimas duas décadas a produção brasileira de milho cresceu rapidamente (Gibbs, Rausch, 2015; Macedo, 2012; Nepstad et al., 2014). Entretanto, a área do milho primeira safra caiu 51% e a do milho segunda safra cresceu 612%. Atualmente $\approx 70\%$ da produção nacional

de milho correspondeu ao milho de sequeiro cultivado extemporaneamente, comumente de janeiro a abril, depois da soja precoce (CONAB, 2021);

6.5.2 Cotações da soja e milho

Um dos objetivos deste estudo é estimar os impactos econômicos do desmatamento e do aumento na concentração de GEE nos rendimentos agrícolas. Para isso, foi necessário projetar o preço da soja e milho praticados no mercado internacional afim de obtermos projeções futuras mais realistas. Para isso, utilizamos a série histórica de preços da soja e do milho dos últimos 60 anos proveniente do banco de dados macroeconômicos *Trading Economics National Statistical* (Figura Suplementar 6.1). Este banco de dados inclui séries de dados que vêm diretamente de fontes oficiais, como bancos centrais e agências nacionais de estatística.




Figura Suplementar 6.1: Preços da soja e do milho praticados no mercado internacional entre 2006 e 2019.

6.5.3 Definição dos períodos de cultivo

Para que os sistemas de dupla safra sejam viáveis, os agricultores precisam garantir que a soja seja colhida precocemente, proporcionando tempo para que o milho segunda safra amadureça enquanto as condições climáticas são favoráveis. Neste contexto, uma das medidas de adaptação à mudança nos padrões climáticos adotada é a postergação ou adianto do plantio

da soja (e conseqüentemente do milho segunda safra) principalmente devido a mudanças na sazonalidade da precipitação.

Visando incorporar a adoção desta medida adaptativa por parte dos produtores estimamos os períodos de cultivo da primeira e segunda safras a partir das datas de início da estação chuvosa identificadas no período histórico e a partir deste ponto as análises foram conduzidas separadamente para cada período visto que as condições climáticas e o manejo das culturas são diferentes. Para isso, assumimos que: (i) O início do plantio é definido pelo início da estação chuvosa; (ii) As cultivares de soja e milho segunda safra plantadas comercialmente no país tem seus ciclos fenológicos de ≈ 120 dias (PIRES *et al.*, 2016; BRUMATTI; PIRES; SANTOS, 2020); (iii) O tempo entre a colheita da soja e o plantio do milho segunda safra pode levar até 20 dias em uma fazenda de porte médio (PIRES *et al.*, 2016; BRUMATTI; PIRES; SANTOS, 2020); (iv) A operação de colheita da soja (primeira safra) e a semeadura do milho segunda safra (segunda safra) são realizadas concomitantemente (BRUMATTI; PIRES; SANTOS, 2020).

Na prática, os dados climáticos diários foram agrupados do início da estação chuvosa (considerado o dia 1) até o 140° dia. Assumimos que grande parte do cultivo e da colheita da soja ocorreram neste período (primeira safra). Na sequência, do 141° dia até o 260° dia (geralmente de janeiro a abril), assumimos ser o período no qual ocorreu o cultivo e colheita do milho segunda safra (segunda safra) (Figura Suplementar 6.2).




Figura Suplementar 6.2: Definição dos períodos de cultivo (Primeira e segunda safras) de acordo com o início da estação chuvosa em cada pixel de 28km x 28km.

6.5.4 Cálculo das anomalias climáticas em cada período de cultivo

Através do cálculo das anomalias removemos as tendências associadas à localização geográfica e elevação, bem como parte da variabilidade interanual associada aos mecanismos climáticos de larga escala, como o sinal da ENSO (*El Niño and the Southern Oscillation*). Dessa forma buscamos isolar os efeitos do desmatamento dos efeitos da variabilidade climática natural. As anomalias climáticas foram estimadas em um processo composto por 3 passos. Esta metodologia foi adaptada de LEITE-FILHO *et al.*, 2021

O passo 1 consistiu na modelagem da variabilidade climática em cada bioma estudado. Para isso, testamos 5 algoritmos de aprendizagem supervisionada visando encontrar aquele que melhor modelasse a variabilidade espacial das temperaturas mínima e máxima, volume de chuvas e início da estação chuvosa na primeira e segunda safras, ou seja, com menor viés em comparação às médias observadas. Foram testados: Support Vector Machine, Random Forest, generalized linear model e generalized additive model). Todos os algoritmos receberam a Latitude (φ), Longitude (λ) e a altitude média (ζ) de cada pixel como variáveis explicativas. A efetividade dos algoritmos em simular o padrão espacial do clima foi avaliada através da diferença entre os valores observados e os valores estimados (viés). Para todas as variáveis climáticas o algoritmo Random Forest (RF) utilizando 1000 árvores foi aquele com maior similaridade em comparação com os valores médios observados. As figuras suplementares 6.3 a 6.5 exibem a média histórica dos acumulados de chuva, temperaturas máxima e mínima e início da estação chuvosa observados e estimados para a primeira e segunda safras utilizando o algoritmo RF.

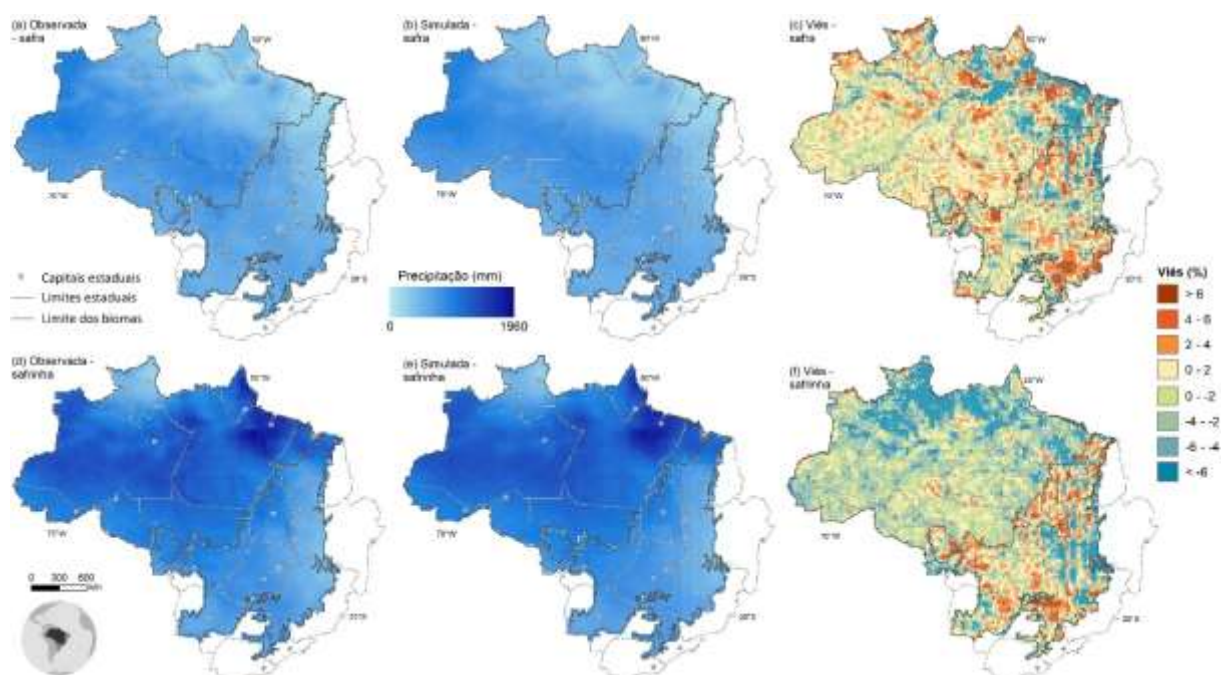


Figura Suplementar 6.3: Precipitações médias observadas durante a (a) primeira safra e (b) segunda safra entre 1999 a 2019. Precipitações médias modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.

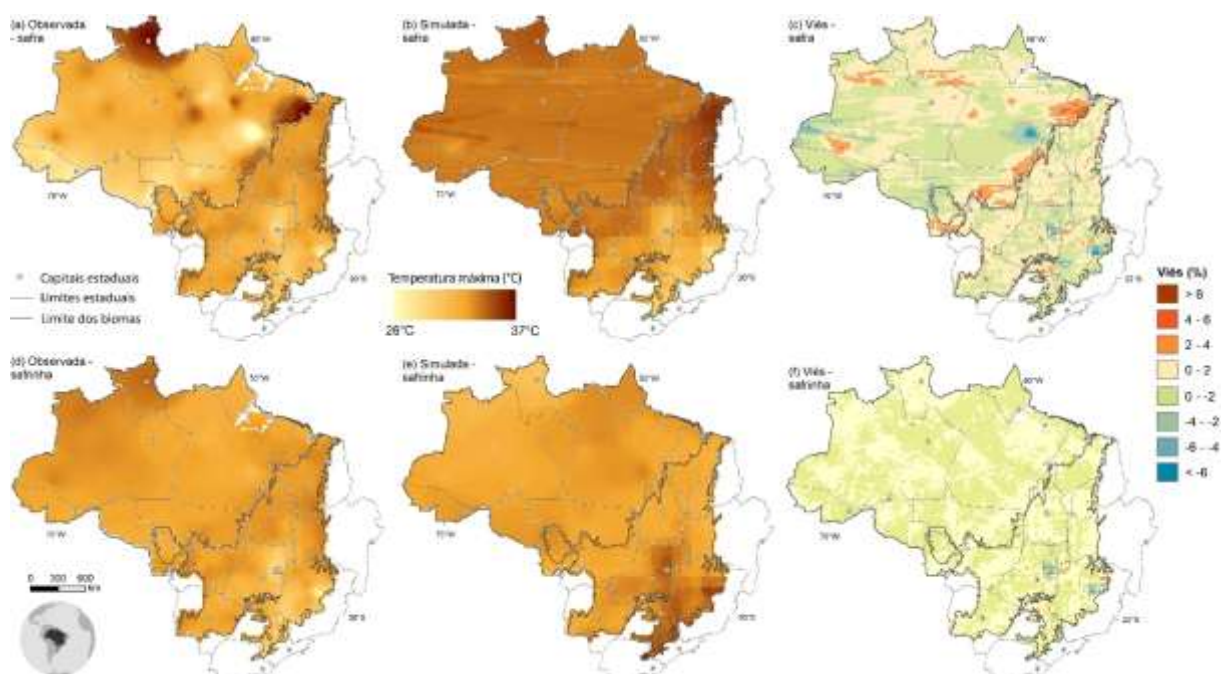


Figura Suplementar 6.4: Temperaturas máximas médias observadas na (a) primeira safra e (b) segunda safra entre 1999 a 2019. Temperaturas máximas modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.

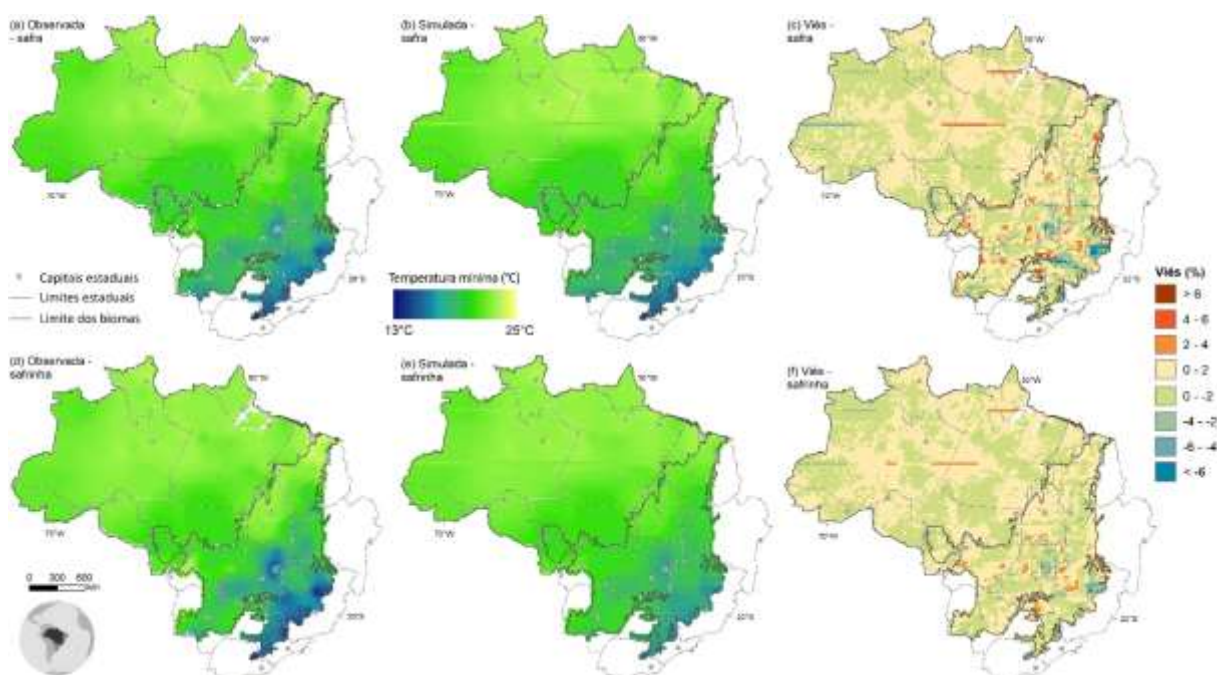


Figura Suplementar 6.5: Temperaturas mínimas médias observadas na (a) primeira safra e (b) segunda safra entre 1999 a 2019. Temperaturas mínimas modeladas para a (c) primeira safra e (d) segunda safra e viés calculado entre os dados observados e os dados estimados na (e) primeira safra e (f) segunda safra para a Amazônia brasileira e o Cerrado.

No passo 2 removemos as tendências climatológicas devido à localização geográfica e a elevação ao calcularmos a diferença entre os valores anuais observados e os valores modelados pelo algoritmo RF. Como o clima simulado pelo algoritmo RF é estático ao longo do tempo, os resultados das equações suplementares 6.3 e 6.4 representam o desvio observado (anomalia) em relação ao padrão climatológico da variabilidade interanual.

$$C1 *_{i,j,t} = (C1_{i,j,t} - \hat{C}_{1,i,j}) \quad (\text{Equação Suplementar 6.2})$$

$$C2 *_{i,j,t} = (C2_{i,j,t} - \hat{C}_{2,i,j}) \quad (\text{Equação Suplementar 6.3})$$

onde, i, j, t representam a dimensão no espaço (i, j) e no tempo (t), $C1_{i,j,t}$ e $C2_{i,j,t}$ representam os valores observados de $R_{i,j,t}$ (mm), $T_{max,i,j,t}$ ($^{\circ}C$), $T_{min,i,j,t}$ ($^{\circ}C$) e $O_{i,j,t}$ (dias) na primeira e segunda safras e $\hat{C}_{1,i,j}$ e $\hat{C}_{2,i,j}$ representam os valores estimados de $R_{i,j,t}$ (mm), $T_{max,i,j,t}$ ($^{\circ}C$), $T_{min,i,j,t}$ ($^{\circ}C$) e $O_{i,j,t}$ (dias) no período da primeira e segunda safras.

Nossa série temporal é relativamente curta (20 anos), portanto, além de existir uma tendência espacial, pode existir um enviesamento associado a um ciclo parcial da Oscilação Decadal do Pacífico (ODP), por exemplo. Como as perdas florestais na região do estudo

umentam monotonicamente em função do tempo, à medida que estas tendências coincidem com o aumento do desmatamento pode haver um enviesamento das nossas análises. Por isso, no terceiro passo subtraímos a precipitação média anual para toda a região de estudo dos resultados das equações suplementares 6.3 e 6.4 para remover o sinal de fatores meteorológicos de larga escala (Equações Suplementares 6.4 e 6.5).

$$C1'_{i,j,t} = C1 *_{i,j,t} - \overline{C1}_t \quad (\text{Equação Suplementar 6.4})$$

$$C2'_{i,j,t} = C2 *_{i,j,t} - \overline{C2}_t \quad (\text{Equação Suplementar 6.5})$$

Onde, $C1 *_{i,j,t}$ e $C2 *_{i,j,t}$ = diferença entre os valores observados de $R_{i,j,t}$ (mm), $Tmax_{i,j,t}$ (°C), $Tmin_{i,j,t}$ (°C) e $O_{i,j,t}$ (day) simulados na primeira e segunda safras, $\overline{C1}_t$ e $\overline{C2}_t$ = médias de $R_{i,j,t}$ (mm), $Tmax_{i,j,t}$ (°C), $Tmin_{i,j,t}$ (°C) e $O_{i,j,t}$ (day) na primeira e segunda safras calculadas para toda a região e $C1'_{i,j,t}$ e $C2'_{i,j,t}$ = anomalias residuais de $R_{i,j,t}$ (mm), $Tmax_{i,j,t}$ (°C), $Tmin_{i,j,t}$ (°C) e $O_{i,j,t}$ (dias) na primeira e segunda safras.

Após estas três etapas, assumimos que os resultados das equações suplementares 6.5 e 6.6, ou seja, os resíduos são as “anomalias” não explicadas pela localização geográfica, elevação ou fatores climáticos de larga escala que são variáveis no tempo. Os valores residuais foram então considerados as anomalias climáticas, as quais associamos com o desmatamento.

6.5.5 Rentabilidade econômica

Obtivemos o custo de produção da soja e do milho (soma dos valores de todos os recursos (insumos e serviços) utilizados no processo produtivo) nos principais municípios produtores a partir das informações da Companhia Nacional de Abastecimento (CONAB). A série histórica dos custos de produção da CONAB diferencia os custos de produção do milho (como primeira safra ou safra única) dos custos de produção do milho segunda safra. Os dados tabulares foram desagregados espacialmente em pixels de 28 x 28 km utilizando como método de interpolação a krigagem ordinária (GREGO; DE OLIVEIRA; VIEIRA, 2014). Para chegar à rentabilidade, dividimos os ganhos econômicos da atividade naquele ano pelo valor do custo de produção. O resultado pode ser expresso em percentual que representa a rentabilidade de produção da soja e do milho no ano correspondente (Figura Suplementar 6.6).

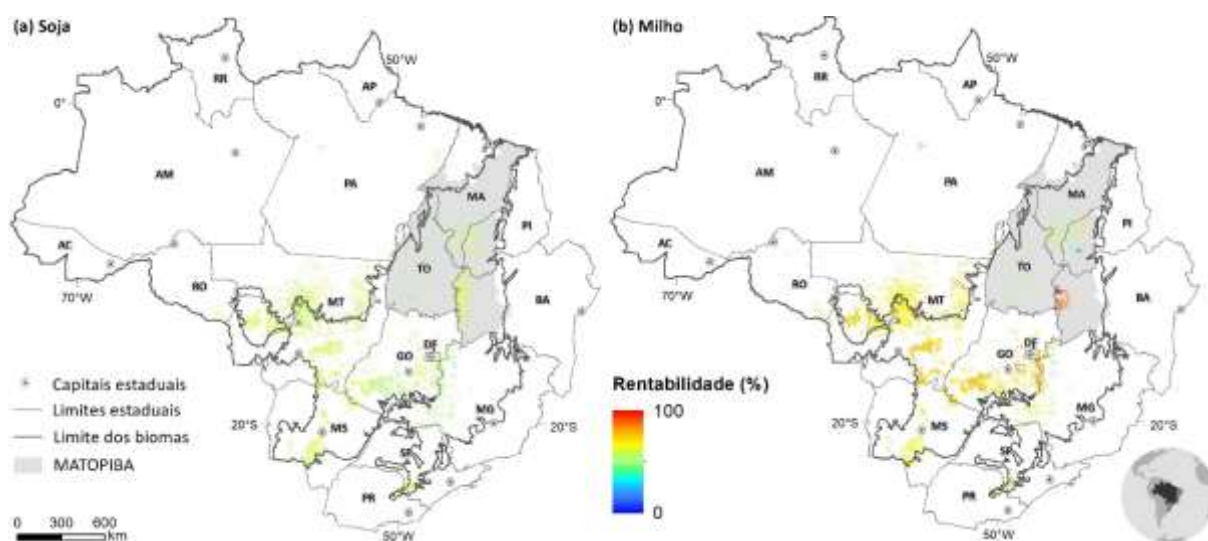


Figura Suplementar 6.6: Rentabilidade na produção de soja e milho na Amazônia e Cerrado calculada a partir do percentual de remuneração do custo de produção da atividade.

Tabela suplementar 6.1: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Amazônia incluindo as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	2228.183	21601.105	0.103	0.918
Área desmatada acumulada	-1175.801	741.648	-1.585	0.113
Início da estação chuvosa (La nina)	597.404	185.286	3.224	0.001
Início da estação chuvosa (El nino)	-455.579	182.498	-2.496	0.013
Início da estação chuvosa (Climatologia)	10.027	2.627	3.817	0.000
Volume de chuvas (La nina)	-8.153	2.564	-3.180	0.001
Volume de chuvas (El nino)	-151.970	37.128	-4.093	0.000
Volume de chuvas (Climatologia)	560.404	203.680	2.751	0.006
Rentabilidade na safra anterior	8.763	10.853	-0.807	0.419
Resíduos do início da estação chuvosa	-1627.885	420.850	-3.868	0.000

Tabela Suplementar 6.2: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Amazônia retirando as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Início da estação chuvosa (La nina)	728.81	196.03	3.72	0.00
Início da estação chuvosa (El nino)	-432.27	192.35	-2.25	0.02
Início da estação chuvosa (Climatologia)	10.84	2.96	3.66	0.00
Volume de chuvas (La nina)	-8.95	2.81	-3.18	0.00
Volume de chuvas (El nino)	-181.10	40.77	-4.44	0.00
Volume de chuvas (Climatologia)	664.07	217.79	3.05	0.00
Rentabilidade na safra anterior	0.23	12.01	0.02	0.98

Tabela Suplementar 6.3: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Cerrado incluindo as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	3793.657	944.806	4.015	0.000
Início da estação chuvosa (La nina)	-13.772	3.704	-3.718	0.000
Rentabilidade na safra anterior	13.329	4.231	-3.151	0.002
Resíduos do início da estação chuvosa	-13.153	3.958	-3.323	0.001
Resíduos do volume de chuvas	0.430	0.818	0.526	0.599
Resíduos da temperatura mínima	122.166	46.470	2.629	0.009

Tabela Suplementar 6.4: Resultados do Modelo Espacial Autorregressivo (SAR) para a primeira safra no bioma Cerrado retirando as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	2374.829	735.272	3.2299	0.001238
Início da estação chuvosa (La nina)	-8.0098	2.8117	-2.8487	0.00439
Rentabilidade na safra anterior	14.0565	4.2792	-3.2848	0.001021

Tabela Suplementar 6.5: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Amazônia incluindo as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	203.1537	12237.23	0.0166	0.986755
Início da estação chuvosa (La nina)	2.9545	1.2291	2.4038	0.016223
Área desmatada acumulada	-361.311	237.0308	-1.5243	0.127428
Resíduos da Temperatura máxima	-2011.9	1833.698	-1.0972	0.272562
Temperatura máxima (climatologia)	656.5118	409.6839	1.6025	0.109049
Temperatura mínima (climatologia)	951.2701	642.6959	1.4801	0.13884
Temperatura mínima (El nino)	-2010.03	734.4792	-2.7367	0.006206

Tabela Suplementar 6.6: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Amazônia retirando as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	9503.731	9649.583	0.9849	0.32468
Início da estação chuvosa (La nina)	3.0641	1.2206	2.5103	0.012063
Temperatura máxima (climatologia)	432.6989	333.2241	1.2985	0.194108
Temperatura mínima (climatologia)	939.9752	643.0858	1.4617	0.143833
Temperatura mínima (El nino)	-2116.76	730.1718	-2.899	0.003744

Tabela Suplementar 6.7: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Cerrado incluindo as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	-40085.99	30894.50	-1.30	0.19
Volume de chuvas (Climatologia)	12.88	3.47	3.71	0.00
Temperatura máxima	2573.19	1035.28	2.49	0.01
Volume de chuvas (La nina)	2924.19	543.45	5.38	0.00
Volume de chuvas (El nino)	-2844.35	544.80	-5.22	0.00
Rentabilidade na safra anterior	106.26	30.30	3.51	0.00
Temperatura máxima (El nino)	-3212.14	1588.52	2.02	0.04
Resíduos da Temperatura máxima	-5779.02	1850.64	-3.12	0.00
Resíduos da Temperatura mínima	-2412.63	1081.88	-2.23	0.03

Tabela Suplementar 6.8: Resultados do Modelo Espacial Autorregressivo (SAR) para a segunda safra no bioma Cerrado retirando as variáveis associadas ao desmatamento.

	Estimativa	Erro padrão	t value	Pr(> z)
Intercepto	-50967.1972	27545.951	-1.8503	0.0642759
Volume de chuvas (Climatologia)	9.2286	3.2618	2.8293	0.0046646
Temperatura máxima	2285.42	1036.3272	2.2053	0.0274325
Volume de chuvas (La nina)	2320.8638	700.9304	3.3111	0.0009292
Volume de chuvas (El nino)	-2207.2167	703.1566	-3.139	0.0016952
Rentabilidade na safra anterior	113.1026	30.604	3.6957	0.0002193
Temperatura máxima (El nino)	-1967.4241	989.1965	-1.9889	0.046711

Tabela suplementar 6.9: Produção de soja e milho (em U\$\$) entre 2003 e 2019.

	Produção brasileira (U\$\$)	Produção da Amazônia (U\$\$)	Produção do Cerrado (U\$\$)	Produção da Amazônia + Cerrado (U\$\$)
Soja	497,9 bilhões	56,8 bilhões	176,7 bilhões	233,5 bilhões
Milho	326,5 bilhões	18,1 bilhões	110,3 bilhões	128,4 bilhões

Tabela suplementar 6.10: Produção no Cerrado e na Amazônia em relação à produção brasileira de soja e milho entre 2003 e 2016.

Produção da Amazônia em relação à produção brasileira	Produção do Cerrado em relação à produção brasileira	Produção da Amazônia + Cerrado em relação à produção brasileira
11.4%	35.5%	46.9%
5.5%	33.8%	39.3%

Tabela suplementar 6.11: Perdas totais na produção de soja e milho no Cerrado e na Amazônia.

	Produção brasileira	Perdas totais Amazônia	Perdas totais Cerrado	Perdas totais Amazônia + Cerrado
Soja	497,9 bilhões	6,2 bilhões	15,4 bilhões	21,6 bilhões
Milho	326,5 bilhões	2,3 bilhões	8,4 bilhões	10,7 bilhões

Tabela suplementar 6.12: Perdas totais no Cerrado e da Amazônia em relação à produção brasileira de soja e milho entre 2003 e 2019.

	Produção perdida na Amazônia em relação à produção brasileira	Produção perdida no Cerrado em relação à produção brasileira	Produção perdida na Amazônia + Cerrado em relação à produção brasileira
	2.5%	6.2%	8.6%
	1.4%	5.1%	6.5%

Tabela suplementar 6.13: Síntese dos impactos econômicos (US\$) associados às quebras de produtividade e ao efeito direto e indireto do desmatamento entre 2003 e 2019.

	AMAZÔNIA		CERRADO		
	Soja	Milho	Soja	Milho	Totais
Perdas potenciais (Todas as causas)	6,2 bilhões	2,3 bilhões	15,4 bilhões	8,4 bilhões	32,2 bilhões
Perdas potenciais (Todas as causas/ano)	440,2 milhões	162,6 milhões	1,1 bilhões	599,4 milhões	2,3 bilhões
Perdas potenciais explicadas pelo modelo	4,2 bilhões	182,1 milhões	12,1 bilhões	6,4 bilhões	22,9 bilhões
Perdas potenciais devido ao Desmatamento	382,7 milhões	5,5 milhões	606,6 milhões	318,9 milhões	1,3 bilhões
Perdas potenciais devido ao Desmatamento por ano	27,3 milhões	390,2 mil	43,3 milhões	22,8 milhões	93,8 milhões

7 CAPÍTULO FINAL

Principal fonte de receita comercial do Brasil, o agronegócio vem sendo afetado pelos eventos adversos do clima e perdas irreversíveis vem sendo registradas. Os prejuízos deixam de se transformar em renda para os agricultores localizados nos Biomas AM e CE, desfalcam o PIB Brasileiro e reduzem as exportações do País. O motivo tem sido a redução expressiva nas colheitas da soja e milho em relação ao potencial esperado. Com isso, a rentabilidade dos produtores é menor, o comércio global dos produtos agropecuários brasileiros se enfraquece e uma menor parcela da demanda global poderá ser atendida, reduzindo as chances de ampliação de novos mercados geradores de receita para o país.

A aplicação de conhecimentos e tecnologias que gerem inovações no setor agrícola poderá minimizar alguns destes impactos negativos causados pela mudança do clima. Algumas das medidas potenciais de adaptação na realidade do milho e soja produzidos no CE e na AM brasileira são abordadas a seguir, passando pelos ajustes de datas de plantio e cultivares, irrigação e formas incrementais de adaptação, uso de fertilizantes, até a transformação em grande escala da agricultura. Porém é improvável que essas sejam as únicas tecnologias que serão importantes nos próximos 40 anos. Ao fim, são apresentados os principais desafios relacionados à adoção das estratégias de adaptação potenciais e o papel da conservação ambiental no Brasil como ferramenta de enfrentamento a um clima cada vez mais inóspito.

7.1 Medidas de adaptação para o milho e soja produzidos no Cerrado e na Amazônia brasileira

As formas de adaptação às mudanças climáticas podem ter características bastante diferentes dependendo da magnitude e principalmente da escala temporal em que as mudanças são sentidas. Em escalas de tempo mais curtas e em resposta a efeitos mais brandos, é esperado que os próprios fazendeiros adaptem seus modos de produção utilizando técnicas que eles já usam para lidar com a variabilidade do clima. Essas formas incrementais de adaptação incluem mudanças de datas de plantio, ajustes na quantidade de fertilizantes e pesticidas e a escolha de outras variedades das culturas que já estejam disponíveis no mercado. À medida que as condições climáticas se distanciam mais das janelas historicamente esperadas, novas tecnologias são desenvolvidas (como novas variedades das culturas) e os produtores começam a adotar sistemas de produção diferentes, como a irrigação. Essas mudanças alteram fundamentalmente os sistemas de produção. Com o tempo e mudanças climáticas mais

severas, essas opções são esgotadas e/ou não são mais percebidas como as mais rentáveis em uma determinada região, levando às chamadas mudanças transformativas. Essas incluem a migração de pessoas e sistemas de produção para outras regiões e mudanças no uso da terra.

7.1.1 Ajustes de datas de plantio e cultivares

No caso de algumas medidas incrementais, como a mudança de datas de plantio, ou a adoção de cultivares com duração de ciclo diferente, há evidências dessas mudanças ocorrendo espontaneamente (PORTER *et al.* 2014). Modelos agronômicos baseados em processos, usados na maioria dos estudos de adaptação, precisam definir essas formas de manejo para realizar suas simulações. Como há um conhecimento bastante limitado de como o clima influencia as decisões de manejo, parte dos impactos simulados que poderiam ser atenuados por esse tipo de ajuste podem também ser entendidos como limitações da modelagem baseada em processos. Já estudos com modelos econométricos, que usam variações observadas na produtividade, muitas vezes já incluem implicitamente esses comportamentos dos produtores. Por isso, algumas distorções podem aparecer entre esses estudos, visto que dependendo do problema em questão essas medidas não são tratadas como adaptação às mudanças climáticas.

Naturalmente, entender o efeito dessas medidas pode ser importante em casos em que há restrições para que os produtores adotem essas mudanças como é o caso dos sistemas DC na AM e CE, onde adaptar as datas de plantio da soja pode significar sacrificar a cultura do milho (PIRES *et al.*, 2016). Como a escolha adequada de datas de plantio e comprimento do ciclo de cultivares a cada ano é essencial para o sucesso econômico desses sistemas, estudos de impactos das mudanças climáticas na dupla safra no Brasil tendem a tratar essas escolhas mais como consequências necessárias dessas mudanças do que como medidas de adaptação cujo potencial deve ser quantificado (PIRES *et al.*, 2016, ABRAHÃO; COSTA, 2018) analisam os impactos da redução da duração da estação chuvosa na área onde sistemas de dupla safra são possíveis, e incluem como medida de adaptação a criação de cultivares de soja e milho com ciclos 20 dias mais curtos do que os atualmente disponíveis. Eles mostram que a existência desses cultivares hipotéticos poderia atenuar a redução da área possível de dupla safra no MATOPIBA de 60% para 30%, e atenuar a variabilidade interanual, e conseqüentemente o risco de adoção, desses sistemas em Mato Grosso.

Boa parte do efeito puro de aumentos de temperatura em modelos agronômicos é associado ao encurtamento do ciclo, que deixa menos tempo para a fotossíntese (MARTINS *et*

al., 2019, MINOLI *et al.*, 2019). Portanto, a adoção de cultivares que diferem na duração do ciclo deve ser priorizada já que já existem uma gama de cultivares facilmente adotáveis às condições do CE e AM com diferentes durações do ciclo (ALLIPRANDINI *et al.*, 2009, CAVASSIM *et al.*, 2013). Porém, cultivares também podem diferir em outras características, principalmente na tolerância ao estresse hídrico e térmico.

7.1.2 Irrigação

A da irrigação geralmente é benéfica sob condições de estresse hídrico severo incluindo trazendo benefícios consideráveis sob condições atuais, já que a adoção de irrigação pode compensar totalmente perdas por aumentos de temperatura até 2 °C (MINOLI *et al.*, 2019). Porém, esse potencial tende a ser maior em regiões mais secas, exatamente aonde a disponibilidade de água para irrigação tende a ser menor. Inclusive, projeções climáticas indicam uma redução da disponibilidade hídrica em regiões mais secas globalmente e uma consequente redução da área irrigável (ELLIOT *et al.*, 2014). Algumas regiões, incluindo partes do sudeste e sul do Brasil, podem experimentar um aumento da área irrigável em cenários de mudanças climáticas (ELLIOT *et al.*, 2014).

Porém, além da questão da sustentabilidade hídrica, os custos de implementação e manutenção de sistemas de irrigação tendem a ser bastante altos. Uma análise da adoção de sistemas de irrigação no Brasil mostra que o produtor irrigante deve ter, além de disponibilidade hídrica, renda suficiente para bancar os custos de implementação, conhecimento técnico do potencial, limitações e operação das tecnologias de irrigação e habilidade administrativa para manejar uma operação mais capitalizada (DA CUNHA *et al.*, 2015). Esses dois fatores fazem com que a irrigação seja menos provável de ser utilizada para adaptação aonde teria os maiores benefícios, em regiões áridas e pobres.

7.1.3 Uso de fertilizantes

O aumento do uso de fertilizantes também tem potencial para contrabalancear alguns dos efeitos das mudanças no clima, mas está longe de ser uma solução genérica. Fertilizantes levam a ganhos marginais decrescentes, e as grandes regiões produtoras de grãos na AM e CE já os utilizam em níveis altos, fazendo com que o uso em quantidades substanciais não tenha um potencial de ganho especialmente alto (FOLEY *et al.*, 2011). Fertilizantes também muitas vezes tem ganhos decrescentes sob maior estresse climático, visto que o aproveitamento dos

nutrientes do solo depende de boas condições climáticas (E.G. TRAVASSO *et al.*, 2006). Muitas regiões do Brasil, na verdade utilizam nutrientes em excesso, o que leva a diversos problemas ambientais, entre eles a emissão de gases de efeito estufa, fazendo com que aumentar o uso global de fertilizantes como adaptação a mudanças no clima possa levar a mais mudanças no clima (WEST *et al.*, 2014).

7.1.4 Transformação em grande escala da agricultura

Além das medidas incrementais adotadas pelos produtores, há também a possibilidade de transformação da agricultura em maiores escalas. Mudanças no clima de uma região podem, por exemplo, fazer com que a produção de determinada cultura não seja mais rentável naquela região, levando a mudanças no uso da terra e a consequente migração de atividades e pessoas. Esse tipo de fenômeno pode ser explorado, ou antecipado, como políticas de adaptação, potencialmente mitigando impactos negativos, como migração em massa, aumentos na desigualdade e a conversão de vegetação natural para uso agrícola (RICKARDS E HOWDEN, 2012; RIPPKE *et al.*, 2016).

As opções transformativas são frequentemente avaliadas dentro de estudos da resposta dos sistemas econômicos a mudanças na produção e produtividade agrícola. Esses estudos capturam implicitamente diversas formas de adaptação simultaneamente, ao nível agregado em modelos de equilíbrio geral ou parcial da economia, incluindo tanto as medidas do lado da oferta de produção mencionadas, como aumento de uso de insumos e migração de culturas, quanto medidas do lado da demanda, como mudanças no consumo e desperdício. Essas características permitem estimar a resposta de diferentes aspectos do sistema produtivo a mudanças de produtividade. NELSON *et al.*, 2014 mostra como os tipos de resposta adaptativa a choques de produtividade sob mudanças climáticas simulados podem variar substancialmente entre modelos estado-da-arte de equilíbrio geral e parcial idealizados para tratar esse problema. O consumo de alimentos, sendo um produto essencial, não muda significativamente em resposta aos choques de produtividade, mas os preços podem aumentar significativamente. Essa falta de resposta na demanda faz com que no mínimo três quartos da resposta aos efeitos das mudanças climáticas na produtividade devem vir de aumentos na intensidade de manejo, mudanças no uso do solo e ajustes nas relações comerciais entre regiões do mundo. Mas os diferentes modelos mostram respostas muito diferentes, indicando um alto grau de incerteza no conhecimento atual das respostas do sistema produtivo.

8 CONSIDERAÇÕES FINAIS

Principal fonte de receita comercial do Brasil, o agronegócio brasileiro vem sendo afetado pelos eventos adversos do clima e este risco aumentará nas próximas duas décadas. Embora os avanços tecnológicos possam, sem dúvidas minimizar alguns destes impactos, os problemas e desafios associadas a esses investimentos ainda precisam ser totalmente avaliados. Grandes projetos de irrigação podem levar à competição por água e energia entre produtores e áreas urbanas (LATHUILLIÈRE; COE; JOHNSON, 2016), exacerbando os conflitos por esses recursos (DOBROVOLSKI; RATTIS, 2015). Tais conflitos já existem em áreas de recente e rápida expansão da irrigação no Brasil (POUSA *et al.*, 2019). Mais pesquisas sobre a sensibilidade de cultivares também podem ser necessárias para traduzir o conhecimento desenvolvido em um contexto temperado para aplicação nos trópicos (ORT; LONG, 2014). Além disso, estratégias históricas de melhoramento genético de plantas podem já estar atingindo o teto de produtividade no País (DE BOSSOREILLE DE RIBOU *et al.*, 2013; LONG; ORT, 2010).

Adicionalmente, as mudanças climáticas têm o potencial de alterar a dinâmica dos sistemas agrícolas por diversos mecanismos, incluindo na taxa de propagação de patógenos e doenças, na eficácia das táticas de controle da disseminação de patógenos (POMMER; BARBOSA, 2009). Devido à ausência de estudos de longo prazo que avaliem a dinâmica da doença sob condições climáticas extremas, ainda não se sabe como isso pode afetar a produtividade das culturas no futuro. Ameaças à intensificação agrícola também requerem pesquisas adicionais, uma vez que o aumento da temperatura e das concentrações de CO₂ afetaria a distribuição geográfica de pragas, doenças e ervas daninhas, apresentando novos desafios ao manejo de culturas e programas de melhoramento (VADEZ; SOLTANI; SINCLAIR, 2012).

Neste sentido, o enfrentamento às mudanças climáticas deve passar invariavelmente por uma transição profunda não apenas na lógica de se usar a terra e produzir, mas de diminuir sensivelmente a pressão para a abertura de novas áreas agrícolas. Uma estratégia robusta de adaptação não pode prescindir somente de uma expectativa de longo prazo focado no desenvolvimento de novos processos, práticas e tecnologias agrícolas. Ao desmatar para produzir, contribui para as mudanças climáticas locais, regionais e globais e assim, acelera o seu próprio fim. Em um país onde a maior parte da produção agrícola depende das chuvas isso

significa que o futuro do agronegócio brasileiro depende da preservação do CE e da AM. As estratégias de adaptação agronômica podem, com certeza, aliviar alguns desses impactos, entretanto, a manutenção da vegetação nativa deve ser parte crítica da solução para a estabilização do clima. As florestas da AM e a vegetal natural do CE são fundamentais para mitigar os efeitos das mudanças climáticas regionalmente e localmente e até diminuí-la, uma vez que são o principal elemento da biota terrestre que atua como sumidouro de carbono, removendo atualmente cerca de 36% das emissões antropogênicas de CO₂ da atmosfera e regulando o clima local.

Portanto, frear o desmatamento não apenas salva a AM e o CE, mas também garante menores riscos à produção de grãos. Diante dessa importância, são necessárias medidas mais rígidas, como zerar o desmatamento legal e ilegal imediatamente, não somente na AM, mas também no CE e por todo o país. O Brasil é capaz de fazer essa redução. Entre 2004 e 2012, o país reduziu em 84% o desmatamento anual na AM, de 27 mil km² para 4,5 mil km² (ASSIS *et al.*, 2019). Além de conservar uma rica sociobiodiversidade e muitos outros serviços ecossistêmicos providos pelas matas brasileiras (STRAND *et al.*, 2018), sua preservação e recuperação também são necessárias para não agravar os impactos negativos ao clima na portentosa agricultura brasileira. A proteção da vegetação nativa brasileira apesar de ser defendida principalmente como medida altruísta do Brasil para ajudar o mundo, é antes de tudo, uma condição essencial para se garantir a prosperidade da agropecuária brasileira. Uma palavra-chave neste contexto é resiliência. A conservação ambiental do CE e da AM é fundamental para incrementar a resiliência dos sistemas de cultivo duplo soja-milho, ou seja, torná-los menos vulneráveis às mudanças do clima global, local e regional. Para isto, são necessários investimentos em pesquisa agropecuária, ações estruturais e comunicação clara e objetiva com a sociedade civil, a fim de ampliar a compreensão dos riscos.

9 REFERÊNCIAS

- ABIMILHO. ABIMILHO – **Estatísticas da Associação Brasileira Das Indústrias Do Milho, 2021**. Disponível em: <http://www.abimilho.com.br/estatisticas>.
- ABRAHÃO, G. M.; COSTA, M. H. **Evolution of rain and photoperiod limitations on the soybean growing season in Brazil: the rise (and possible fall) of double cropping systems**. *Agricultural and Forest Meteorology*, 256, 2018, p. 32-45.
- AGUDELO, J. et al. **Influence of longer dry seasons in the southern Amazon on patterns of water vapor transport over Northern South America and the Caribbean**. *Climate Dynamics*, 52, 2019, p. 2647-2665.
- AKKERMANS, T.; THIERY, W.; LIPZIG, N. **The regional climate impact of a realistic future deforestation scenario in the Congo Basin**. *Journal of Climate*, 27, 2014, p. 2714–2734.
- ALKAMA, R.; CESCATTI, A. **Biophysical climate impacts of recent changes in global forest cover**. *Science*, 351, 2016, p. 600-604.
- ANA. **Atlas irrigação: uso da água na agricultura irrigada**. [S.l.], 2017.
- ANA; IBGE. **Uso da água na agricultura de sequeiro no Brasil (2013-2017)**. Agência Nacional de Águas, Brasília, 2020, p. 63.
- ARAGÃO, L. E. O. C. et al. **Spatial patterns and fire response of recent Amazonian droughts**. *Geophysical Research Letters*, 34, 2007.
- ARCTIC COUNCIL. **Glossary of terms**. In: **Arctic Council Arctic Resilience Interim Report 2013** (Stockholm, Sweden: Stockholm Environment Institute and Stockholm Resilience Centre). [S.l.], 2016, v. 8.
- ARRHENIUS, S. **The influence of carbonic acid in the air upon the temperature of the ground**. *Philosophical Magazine and Journal of Science*, 41, Apr. 1896, p. 237-276.
- ASSAD, E. D. et al. **Sistema de previsão da safra de soja para o Brasil**. *Pesquisa Agropecuária Brasileira*. Scielo, May 2007, p. 615-625.
- ASSIS, L. F. G. et al. **TerraBrasilis: a spatial data analytics infrastructure for large-scale thematic mapping**. *ISPRS - International Journal of Geo-Information*, 8, n. 11, 2019.
- AZEVEDO, Tasso et al. **Relatório anual do desmatamento no Brasil**. *MapBiomias*, Jul. 2022.
- BAGLEY, J. E. et al. **Drought and deforestation: has land cover change influenced recent precipitation extremes in the Amazon?** *Journal of Climate*, 27, 2014, p. 345–361.
- BALLARI, D.; CASTRO, E.; CAMPOZANO, L. **Validation of satellite precipitation (TRMM 3B43) in Ecuadorian coastal plains, Andean highlands, and Amazonian**

rainforest. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B8, 2016, p. 305-311.

BARICHIVICH, J. et al. **Recent intensification of Amazon flooding extremes driven by strengthened Walker circulation.** Science Advances, 4, 2018
Barkhordarian, A. et al. A recent systematic increase in vapor pressure deficit over tropical South America. Sci Rep, 9, n. 15331, 2019.

BATISTA, E. ET AL. **Large-scale pasture restoration may not be the best option to reduce greenhouse gas emissions in Brazil.** Environmental Research Letters, 14, 2019.

BERLATO, M. A.; Fontana, D. C. **Impacts of El Niño and La Niña on agricultural production in southern Brazil and the use of climate forecasts in agriculture.** Embrapa, Passo Fundo, 2001, p. 217-241.

BETTS, R. Met Office: **Atmospheric CO₂ now hitting 50% higher than pre-industrial levels.** Carbon Brief, 16 Mar. 2021. BNDES.

BOERS, N. et al. **A deforestation-induced tipping point for the South American monsoon system.** Scientific reports, 25 jan. 2017., p. 9

BONAN, G. B. **Forests and climate change: forcings, feedbacks, and the climate benefits of forests.** Science, 320, 2008., p. 1444-144

BRASIL. **Lei no 12.651 de 25 de maio de 2012.** Planalto.gov, 2012. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm.

BRUMATTI, L. M.; PIRES, G. F.; SANTOS, A. B. **Challenges to the adaptation of double cropping agricultural systems in Brazil under changes in climate and land cover.** Atmosphere, 11, n. 12, 2020.

BUTT, N.; DE OLIVEIRA, P. A.; COSTA, M. H. **Evidence that deforestation affects the onset of the rainy season in Rondonia, Brazil.** Advancing earth and space science, 116, 15 jun. 2011.

CASTRO, N. R. et al. **Aumento dos custos causa queda de 0,8% no PIB do agronegócio neste.** Centro de Estudos Avançados em Economia Aplicada – CEPEA. [S.l.]. 2022.

CHADDAD, F. **The economics and organization of Brazilian agriculture: recent evolution and productivity gains.** Elsevier, San Diego, 2016.

CLARKE, R. T. et al. **Issues of spatial correlation arising from the use of TRMM rainfall estimates in the Brazilian Amazon.** Water Resour. Res., 47, n. W05539, 2011.

COHN, A. S. et al. **Cropping frequency and area response to climate variability can exceed yield response.** Nature Climate Change, 6, 2016., p. 601–604

COHN, A. S. et al. **Forest loss in Brazil increases maximum temperatures within 50 km.** Environmental Research Letters, 14, 14 ago. 2019.

COLLISCHONN, B. et al. **Desempenho do satélite TRMM na estimativa de precipitação sobre a bacia do Paraguai superior.** Rev. Bras. Cartografia, 59, 2007., p. 93-99CONAB.

CORONEL, D. A. **Impactos da política de desenvolvimento produtivo na economia brasileira,** Viçosa, 2010.

COSTA, M. et al. **Climate risks to Amazon agriculture suggest a rationale to conserve local ecosystems.** Frontiers in Ecology and the Environment, 17, n. 10, 2019., p. 584-590.

COSTA, M. H. et al. **Climate change in Amazonia caused by soybean cropland expansion as compared to caused by pastureland expansion.** Geophys. Res. Lett., 34, 2007.

COSTA, M. H. **Large-scale hydrological impacts of tropical forest conversion.** In: BONELL, M.; BRUIJNZEEL, L. A. Forests, water and people in the humid tropics. [S.l.]: [s.n.], 2005., p. 590-597. ISBN 9780511535666.

COSTA, M. H.; PIRES, G. F. **Effects of Amazon and Central Brazil deforestation scenarios on the duration of the dry season in the arc of deforestation.** International Journal of Climatology, 30, 20 nov. 2009., p. 1970-1979.

COSTA, M. H.; PIRES, G. F. **Effects of Amazon and Central Brazil deforestation scenarios on the duration of the dry season in the arc of deforestation.** Int. J. Climatol., 2010., p. 1970-1979.

COSTA, M.; ABRAHÃO, G. M. **Identificação das relações entre eventos anômalos de precipitação e quebras de safra de soja, milho e cana-de-açúcar no Brasil nas últimas duas décadas.** Iniciativa para o uso da terra, mar. 2017.

CRAMÉR, H. **Mathematical methods of statistics ch. 21.** Princeton University Press, 1946.

CULF, A. D.; FISCH, G.; HODNETT, M. **The albedo of Amazonian forest and ranch land.** Journal of Climate, 8, n. 6, 1995., p. 1544-1554.

DA SILVA, R. R.; WERTH, D.; AVISSAR, R. **Regional impacts of future land-cover changes on the Amazon Basin wet-season climate.** Journal of Climate, 21, 2008., p. 1153–1170.

D'ALMEIDA, C. et al. **The effects of deforestation on the hydrological cycle in Amazonia: a review on scale and resolution.** International Journal of Climatology, 10 Apr. 2007.

DE BOSSOREILLE DE RIBOU, S. et al. **Plant science and agricultural productivity: why are we hitting the yield ceiling?** Plant Sci., 210, 2013., p. 159–176.

DEBORTOLI, N. et al. **Detecting deforestation impacts in southern Amazonia rainfall using rain gauges.** International Journal of Climatology, 37, 2016., p. 2889-2900.

DICKINSON, R. E.; KENNEDY, P. **Impacts on regional climate of Amazon deforestation.** Geophysical Research Letters, 19, 1992., p. 1947–1950.

DOBROVOLSKI, R.; RATTIS, L. **Water collapse in Brazil: the danger of relying on what you neglect.** *Nat. E Conserv.*, 13, 2015.

EFRON, B.; STEIN, C. **The jackknife estimate of variance.** *The Annals of Statistics*, 9, n. 3, 1981., p. 586-596.

EMBRAPA. **Tecnologias de produção de soja - Região Central do Brasil 2008.** Londrina: [s.n.], 2008. p. 280. ISBN ISSN 1677-8499.

ERA5. **ECMWF.** Disponível em: <https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5>.

EVANS, S. **Analysis: which countries are historically responsible for climate change? Carbon Brief, 05 Oct. 2021.** Disponível em: <https://www.carbonbrief.org/analysis-which-countries-are-historically-responsible-for-climate-change/>.

FAO. **Global Forest Resources Assessment 2005: progress towards sustainable forest management.** Food and Agriculture Organization. Rome. 2006.

FAO. **FAOSTAT** - Food and Agriculture Organization of the United Nations, 2020. [S.l.]. 2020.

FLACH, R. et al. **Conserving the Cerrado and Amazon biomes of Brazil protects the soy economy from damaging warming.** *Elsevier World Development*, 146, 9 Jul. 2021., p. 16.

FREITAS JR., **Dez grupos têm um terço da nova fronteira da soja.** *O Valor Econômico*, 01 Apr. 2013.

FRIES, C. D.; CORONEL, D. A. **A competitividade das exportações gaúchas de soja em grão (2001-2012).** *Pesquisa e Debate*, 25, 2014., p. 163-189.

FU, R.; LI, W. **The influence of the land surface on the transition from dry to wet season in Amazonia.** *Theoretical and Applied Climatology*, 78, 2004.

GASH, J. H. C. et al. **Amazonian deforestation and climate.** *Institute of Hydrology*. [S.l.], p. 437-458. 1996.

GATTI, L. V. et al. **Amazonia as a carbon source linked to deforestation and climate change.** *Nature*, 595, 2021., p. 388–393.

GOOSSE, H. et al. **The origin of the European "Medieval Warm Period".** *European Geosciences Union. Clim. Past*, 2, 2006., p. 99–113.

GREGO, C. R.; DE OLIVEIRA, R. P.; VIEIRA, S. R. **Geoestatística aplicada a agricultura de precisão.** In: BERNARDI, A. C.; NAIME, J.; RESENDE, A. *Agricultura de precisão: resultados de um novo olhar.* [S.l.]: Embrapa Instrumentação, 2014.

GREGO, C. R.; VIEIRA, S. R. **Variabilidade espacial de propriedades físicas do solo em uma parcela experimental.** *Revista Brasileira de Ciência do Solo*, 29, n. 2, 2005., p. 169-177.

GROVE, J. M. **The Little Ice Age**. Methuen & Co, 1988., p. 1-198.

HAYNES, W. M.; LIDE, D. ; BRUNO, T. J. **CRC Handbook of Chemistry and Physics**. [S.l.]: Taylor & Francis Group, v. 95, 2014. ISBN 978-1-4822-0868-9.

HIRAKURI, M. H.; LAZZAROTTO, J. J. **Evolução e perspectivas de desempenho econômico associadas com a produção de soja nos contextos mundial e brasileiro**. Embrapa-Soja, Londrina, 2011., p. 68.

HIRAKURI, M. H.; LAZZAROTTO, J. J. **O agronegócio da soja nos contextos mundial e brasileiro**. Embrapa Soja, Londrina, Jun. 2014., p. 70.

HSIAO, C. **Analysis of panel data**. Cambridge: Cambridge University Press, 1986. ISBN ISBN 0-521-81855-9.

HURLIN, C. **Testing Granger causality in heterogeneous panel data models**. *Revue Économique*, 56, n. 3, 2005., p. 799-809.

IBGE. **Produção Agrícola Municipal 2021**. Instituto Brasileiro de Geografia e Estatística. [S.l.]. 2022. Disponível em: www.sidra.ibge.gov.br. 2022.

IIZUMI, T.; SAKAI, T. **The global dataset of historical yields for major crops 1981–2016**. *Sci Data*, 7, 2020.

INPE; **PRODES. INPE database**, 2020. Disponível em: www.obt.inpe.br/prodes/index.php.

IPCC. **Workshop on describing scientific uncertainties in climate change to support analysis of risk of options**. IPCC. Geneva. 2004.

IPCC. **Climate change 2014: synthesis report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**. Intergovernmental Panel on Climate Change. Geneva. 2015.

KEYS, P. W. et al. **Approaching moisture recycling governance**. *Elsevier*, 45, jul. 2017., p. 15-23

KHANNA, J. et al. **Regional dry-season climate changes due to three decades of Amazonian deforestation**. *Nature*, 7, 20 fev. 2017., p. 200–204

LAMBIN, E. F.; MEYFROIDT, P. **Global land use change, economic globalization, and the looming land scarcity**. *Proc. Natl. Acad. Sci. U. S. A.*, 108, n. 9, 2011., p. 3465–3472

LATHUILLIÈRE, M. J.; COE, M. T.; JOHNSON, M. S. **A review of green- and blue-water resources and their trade-offs for future agricultural production in the Amazon Basin: what could irrigated agriculture mean for Amazonia?** *Hydrol. Earth Syst. Sci.*, 20, 2016., p. 2179–2194

LAWRENCE, D.; VANDECAR, K. **Effects of tropical deforestation on climate and agriculture**. *Nature Climate Change*, 18 dez. 2014., p. 27–36

- LEITE-FILHO, A. T. et al. **Deforestation reduces rainfall and agricultural revenues in the Brazilian Amazon.** *Nature*, 12, 2021.
- LEITE-FILHO, A. T.; COSTA, M. H.; FU, R. **The Southern Amazon rainy season: the role of deforestation and its interactions with large-scale mechanisms.** *The International Journal of Climatology*, 40, 2019., p. 2328-2341
- LEITE-FILHO, A. T.; PONTES, V. Y. D. S.; COSTA, M. H. **Effects of deforestation on the onset of the rainy season and the duration of dry spells in southern Amazonia.** *JGR: Atmospheres*, 21 abr. 2019a.
- LENSSSEN, N. J. L. et al. **Improvements in the GISTEMP uncertainty model.** *JGR Atmospheres*, 23 maio 2019., p. 6307 - 6326A
- LESK, C.; ROWHANI, P.; RAMANKUTTY, N. **Influence of extreme weather disasters on global crop production,** 529, 06 jan. 2016., p. 84-87
- LONG, S. P.; ORT, D. R. **More than taking the heat: crops and global change.** *Curr. Opin. Plant Biol.*, 13, 2010., p. 240–247
- LOVEJOY, T. E.; NOBRE, C. **Amazon tipping point,** 4, 21 fev. 2018.
- MAKARIEVA, A. M.; GORSHKOV, V. G.; LI, B. L. **Precipitation on land versus distance from the ocean: evidence for a forest pump of atmospheric moisture.** *Ecological Complexity*, 6, 2009., p. 302-307
- MAPBIOMAS. <https://mapbiomas.org>. MapBiomass, 2021. Acesso em: 2021.
- MARTINELLI, A. et al. **Sugar and ethanol production as a rural development strategy in Brazil: evidence from State of São Paulo.** *Agricultural Systems*, 104, 2011., p. 419-428
- MASSON-DELMOTTE, V. et al. **Climate Change 2021 The Physical Science Basis.** IPCC. [S.l.]. 2021. (978-92-9169-158-6).
- MATTHEWS, J. B. R. et al. **Special Report 15.** IPCC, 2018., p. 55
- MCTI. **Estimativas anuais de emissões de gases de efeito estufa no Brasil.** Brasília, 2021.
- MINISTÉRIO DA AGRICULTURA, P. E. A. **Projeções do agronegócio 2018/19 a 2028/29.** Brasília, Distrito Federal. 2019.
- MOLINA, R. R. et al. **Exponential growth of precipitation along a “forest-fed moisture convey or belt” above the Amazon.** *Journal of Geophysical Research-Atmospheres*, 124, 2019., p. 2589–2599
- MYERS, N. et al. **Biodiversity hotspots for conservation priorities.** *Nature*, 403, 2000., p. 853-858

- NOBLET, N. et al. **Determining robust impacts of land-use-induced land cover changes on surface climate over North America and Eurasia: results from the first set of LUCID experiments.** *Journal of Climate*, 25, 2012.
- NOBRE, P. et al. **Amazon deforestation and climate change in a coupled model simulation,** 5686–5697, 01 nov. 2009., p. 5686–5697
- NÓBREGA, R. S.; SOUZA, E. P.; GALVÍNCIO, J. D. **Análise da estimativa de precipitação do TRMM em uma sub-bacia da Amazônia Ocidental.** *Revista de Geografia, Recife*, 25, n. 1, 2008.
- OLIVEIRA, P. T. S. et al. **Trends in water balance components across the Brazilian Cerrado.** Gupta, 2014.
- ORT, D.; LONG, S. P. **Limits on yields in the Corn Belt.** *Science*, 344, n. 6183, 2014., p. 484–485
- ORTIZ-BOBEA, A. et al. **Anthropogenic climate change has slowed global agricultural productivity growth.** *Nature Climate Change*, 01 abr. 2021., p. 306–312
- PAIVA, R. C. D. et al. **Reduced precipitation over large water bodies in the Brazilian Amazon shown from TRMM data.** *Geophys. Res. Lett.*, 38, n. L04406, 2011.
- PIRES, G. F. et al. **Increased climate risk in Brazilian double cropping agriculture.** Elsevier, 2016., p. 286 – 298
- PIRES, G. F.; COSTA, M. H. **Deforestation causes different subregional effects on the Amazon bioclimatic equilibrium.** *Geophysical Research Letters*, 40, 20 maio 2013., p. 3618–3623
- POMMER, C. V.; BARBOSA, W. **The impact of breeding on fruit production in warm climates of Brazil.** *Rev. Bras. Frutic*, 31, 2009., p. 612–634
- PONGRATZ, J. C. et al. **Bio-geophysical versus biogeochemical climate response to historical anthropogenic land cover change.** *Geophysical Research Letters*, 37, 2010.
- PÖRTNER, H. O.; ROBERTS, M., D. C.; TIGNOR, E. S. P. **Climate change 2022: impacts, adaptation, and vulnerability.** Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. IPCC, 2022.
- POTENZA, R. F. et al. **Análise das emissões brasileiras de gases de efeito estufa e suas implicações para as metas climáticas do Brasil 1970 – 2020.** [S.l.]. 2021.
- POUSA, R. et al. **Climate change and intense irrigation growth in Western Bahia, Brazil: the urgent need for hydroclimatic monitoring.** *Water*, 11, n. 5, 2019.
- RAJÃO, R. et al. **The rotten apples of Brazil’s agribusiness.** *Science*, 369, n. 6501, 2020., p. 246-248

RAMOS-DA-SILVA, R. et al. **Cloud streets and land-water interactions in the Amazon.** *Biogeochemistry*, 105, 2011., p. 201-211

RATTIS, L. et al. **Climatic limit for agriculture in Brazil.** *Nature Climate Change*, 11, 11 Nov. 2021., p. 1098–1104

ROCHEDO, P. R. R. et al. **The threat of political bargaining to climate mitigation in Brazil.** *Nature Climate Change*, 8, 2018., p. 695-698

SAAD, S. et al. **Can the deforestation breeze change the rainfall in Amazonia? A case study for the BR-163 highway region.** *Earth Interactions*, 14, 19 Jul. 2010., p. 25

SAMPAIO, G. et al. **Regional climate change over eastern Amazonia caused by pasture and soybean cropland expansion.** *Geophysical Research Letters*, 34, 2007.

SCHLESINGER, S.; NORONHA, S. **O Brasil está nu! O avanço da monocultura da soja: o grão que cresceu demais.** FASE, Rio de Janeiro, 2006.

SENA, E.; ARTAXO, P.; CORREIA, A. **Spatial variability of the direct radiative forcing of biomass burning aerosols and the effects of land use change in Amazonia.** *Atmospheric Chemistry & Physics*, 13, 2013., p. 1261-1275

SENN, M. C. A.; COSTA, M. ; PIRES, G. F. **Vegetation-atmosphere-soil nutrient feedbacks in the Amazon for different deforestation scenarios.** *Journal of Geophysical Research: Atmospheres*, 114, 2009. Disponível em: <https://doi.org/10.1029/2008JD010401>.

SHEIL, D.; MURDIYARSO, D. **How forests attract rain: An examination of a new hypothesis.** *Bioscience*, 59, 2009., p. 341–347

SILVÉRIO, D. V. et al. **Agricultural expansion dominates climate changes in southeastern Amazonia: The overlooked non-GHG forcing.** *Environ. Res. Lett.*, 10, 2015.

SINDIRAÇÕES. **Sindicato Nacional da Indústria de Alimentação Animal, 2021.** Disponível em: sindiracoes.org.br/produtos-e-servicos/boletim-informativo-do-setor.

SIQUEIRA, O. J. W. et al. **Mudanças climáticas projetadas através dos modelos GISS e reflexos na produção agrícola brasileira.** *Revista Brasileira de Agrometeorologia*, 8, n. 2, 2000., p. 311-320

SIQUEIRA, O. J. W. et al. **Efeitos potenciais das mudanças climáticas na agricultura brasileira e.** In: LIMA, M. A.; CABRAL, O. M. R.; GONZALEZ MIGUEZ, J. D. *Mudanças climáticas globais e a agropecuária brasileira.* Jaguariúna: Embrapa, 2001., p. 33-63. ISBN ISBN 85-85771-13-5.

SMITH, P. et al. **Agriculture, forestry and other land use. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change,** 2014., p. 811-922

- SNEYERS, R. **Sur l'analyse statistique des series d'observations.** Organisation Météorologique Mondial. Genève, p. 192. 1975.
- SOARES-FILHO, B. S. et al. **Brazil's market for trading forest certificates.** PLoS One, 11, 2016.
- SPEARMAN, C. **The proof and measurement of association between two things.** The American Journal of Psychology, 15, 1904., p. 72–101
- SPERA, S. A. et al. **Land-use change affects water recycling in Brazil's last agricultural frontier.** Glob. Change Biol., 22, 2016., p. 3405–3413
- SPRACKLEN, D. V.; ARNOLD, S. R.; TAYLOR, C. M. **Observations of increased tropical rainfall preceded by air passage over forests.** Nature, 489, 05 jul. 2012., p. 282–285
- STAAL, A. et al. **Feedback between drought and deforestation in the Amazon.** Environmental Research Letters, 15, 2020.
- STRAND, J. et al. **Spatially explicit valuation of the Brazilian Amazon forest's ecosystem services.** Nat Sustain, 1, 2018., p. 657–664
- SUMILA, T. C. A. et al. **Sources of water vapor to economically relevant regions in Amazonia and the effect of deforestation.** Journal of Hydrometeorology, 18, jun. 2017., p. 13
- SWANN, A. S. et al. **Future deforestation in the Amazon and consequences for South American climate.** Agricultural and Forest Meteorology, 2015.
- TEAM, G. **GISS Surface Temperature Analysis version.** NASA Goddard Institute for Space Studies, 2022.
- TRASE. **Transparency for Sustainable Economies, SEI-PCS Brazil soy (v.2.3).** Transparency for Sustainable Economies. [S.l.], p. 8. 2021.
- VADEZ, V.; SOLTANI, A.; SINCLAIR, T. R. **Modelling possible benefits of root related traits to enhance terminal drought adaptation of chickpea.** Field Crops Research, 137, 2012., p. 108–115
- VAN DER ENT, R. J. et al. **Origin and fate of atmospheric moisture over continents.** Water Resources Research, 46, n. W09525, 2010.
- WANG, S. et al. **Recent global decline of CO₂ fertilization effects on vegetation photosynthesis.** Science, 370, 11 dez. 2020., p. 1295-1300
- WRIGHT, J. S. et al. **Rainforest-initiated wet season onset over the southern Amazon,** 114, 20 jul. 2017., p. 8481-8486
- XAVIER, A. C. et al. **New improved Brazilian daily weather gridded data (1961–2020),** 2022.

YANAGI, S. D. N. M. **Albedo de uma floresta tropical amazônica: medições de campo, sensoriamento remoto, modelagem, e sua influência no clima regional.** Universidade Federal de Viçosa, 31 out. 2006. Disponível em: <http://locus.ufv.br/handle/123456789/1507>.

ZENG, N.; NEELIN, J. D. A. **Land-atmosphere interaction theory for the tropical deforestation problem.** *Journal of Climate*, 12, 01 mar. 1999., p. 857–872

ZHANG, H.; HENDERSON-SELLERS, A.; MCGUFFIE, K. **Impacts of tropical deforestation. Part I: process analysis of local climatic change.** *Journal Article*, 7, jul. 1996., p. 1497-1517

8 GLOSSÁRIO

Agenda 2030 para o Desenvolvimento Sustentável: Uma resolução da ONU em setembro de 2015 adotando um plano de ação para as pessoas, o planeta e a prosperidade em uma nova estrutura de desenvolvimento global ancorada em 17 Objetivos de Desenvolvimento Sustentável (ONU, 2015).

Adaptação: Nos sistemas humanos, o processo de ajuste ao clima real ou esperado e seus efeitos, a fim de moderar danos ou explorar oportunidades benéficas. Nos sistemas naturais, o processo de ajuste ao clima real e seus efeitos; a intervenção humana pode facilitar o ajuste ao clima esperado e seus efeitos.

Opções de adaptação: O conjunto de estratégias e medidas que estão disponíveis e apropriadas para abordar a adaptação. Eles incluem uma ampla gama de ações que podem ser categorizadas como estruturais, institucionais, ecológicas ou comportamentais.

Capacidade adaptativa: A capacidade de sistemas, instituições, humanos e outros organismos de se ajustarem a danos potenciais, aproveitar oportunidades ou responder às consequências.

Albedo: A fração da radiação solar refletida por uma superfície ou objeto, geralmente expressa em porcentagem. As superfícies cobertas de neve têm um albedo alto, o albedo da superfície dos solos varia de alto a baixo, e as superfícies cobertas de vegetação e os oceanos têm um albedo baixo. O albedo planetário da Terra muda principalmente através da variação de nebulosidade, neve, gelo, área foliar e mudanças na cobertura da terra.

Resíduo (anomalia): O desvio de uma variável do seu valor médio ao longo de um período de referência.

Emissões antropogênicas: Emissões de gases de efeito estufa (GEEs), precursores de GEEs e aerossóis causados por atividades humanas. Essas atividades incluem a queima de combustíveis fósseis, desmatamento, uso da terra e mudanças no uso da terra (LULUC), produção de gado, fertilização, gestão de resíduos e processos industriais.

Inteligência Artificial (IA): Sistemas computacionais capazes de realizar tarefas que normalmente requerem inteligência humana, como percepção visual e reconhecimento de fala.

Atmosfera: O envelope gasoso que envolve a Terra, dividido em cinco camadas - a troposfera que contém metade da atmosfera terrestre, a estratosfera, a mesosfera, a termosfera e a exosfera, que é o limite externo da atmosfera. A atmosfera seca consiste quase inteiramente de nitrogênio (taxa de mistura em volume de 78,1%) e oxigênio (taxa de mistura em volume de 20,9%), juntamente com vários gases traços, como argônio (taxa de mistura em volume de 0,93%), hélio e gases de efeito estufa radiativamente ativos. (GHGs) como dióxido de carbono (CO₂) (proporção de mistura em volume de 0,04%) e ozônio (O₃). Além disso, a atmosfera contém o vapor d'água de GEE (H₂O), cujas quantidades são altamente variáveis, mas normalmente em torno de 1% de proporção de mistura em volume. A atmosfera também contém nuvens e aerossóis.

Clima: Clima em sentido estrito é geralmente definido como o tempo médio, ou mais rigorosamente, como a descrição estatística em termos da média e variabilidade de quantidades relevantes ao longo de um período de tempo que varia de meses a milhares ou milhões de anos. O período clássico para a média dessas variáveis é de 30 anos, conforme definido pela Organização Meteorológica Mundial. As quantidades relevantes são na maioria das vezes variáveis de superfície, como temperatura, precipitação e vento. Clima em um sentido mais amplo é o estado incluindo uma descrição estatística, do sistema climático.

Mudanças Climáticas: A mudança climática refere-se a uma mudança no estado do clima que pode ser identificada (por exemplo, usando testes estatísticos) por mudanças na média e/ou na variabilidade de suas propriedades e que persiste por um período prolongado, geralmente décadas ou mais. As mudanças climáticas podem ser devidas a processos internos naturais ou forças externas, como modulações dos ciclos solares, erupções vulcânicas e mudanças antrópicas persistentes na composição da atmosfera ou no uso da terra. Observe que a Convenção-Quadro sobre Mudanças Climáticas (UNFCCC, em inglês), em seu Artigo 1, define mudança climática como: “uma mudança do clima que é atribuída direta ou indiretamente à atividade humana que altera a composição da atmosfera global e que se soma à variabilidade natural do clima observada em períodos de tempo comparáveis”. A UNFCCC, portanto, faz uma distinção entre as mudanças climáticas atribuíveis às atividades humanas que alteram a composição atmosférica e a variabilidade climática atribuível a causas naturais.

Clima extremo (ou evento climático extremo): A ocorrência de um valor de uma variável meteorológica ou climática acima (ou abaixo) de um valor limite próximo às extremidades superiores (ou inferiores) do intervalo de valores observados da variável.

Feedback climático: Uma interação na qual uma perturbação em uma quantidade climática causa uma mudança em uma segunda e a mudança na segunda quantidade, em última análise, leva a uma mudança adicional na primeira. Um feedback negativo é aquele em que a perturbação inicial é enfraquecida pelas mudanças que causa; um feedback positivo é aquele em que a perturbação inicial é aumentada. A perturbação inicial pode ser forçada externamente ou surgir como parte da variabilidade interna.

Variabilidade climática: A variabilidade climática refere-se a variações no estado médio e outras estatísticas (como desvios padrão, ocorrência de extremos, etc.) do clima em todas as escalas espaciais e temporais além daquelas de eventos climáticos individuais. A variabilidade pode ser devida a processos internos naturais dentro do sistema climático (variabilidade interna), ou a variações no forçamento externo natural ou antropogênico (variabilidade externa).

Detecção e atribuição: A detecção de mudança é definida como o processo de demonstrar que o clima ou um sistema afetado pelo clima mudou em algum sentido estatístico definido, sem fornecer uma razão para essa mudança. Uma mudança identificada é detectada em observações se sua probabilidade de ocorrência por acaso devido apenas à variabilidade interna for determinada como pequena, por exemplo, <10%. A atribuição é definida como o processo de avaliar as contribuições relativas de múltiplos fatores causais para uma mudança ou evento com uma avaliação formal de confiança.

Seca: Um período de tempo anormalmente seco longo o suficiente para causar um sério desequilíbrio hidrológico. Seca é um termo relativo, portanto, qualquer discussão em termos de déficit de precipitação deve se referir à atividade específica relacionada à precipitação que está em discussão. Por exemplo, a escassez de precipitação durante a estação de crescimento afeta a produção agrícola ou a função do ecossistema em geral (devido à seca da umidade do solo, também chamada de seca agrícola), e durante a estação de escoamento e percolação afeta principalmente o abastecimento de água (seca hidrológica). Mudanças de armazenamento na umidade do solo e águas subterrâneas também são afetadas por aumentos na evapotranspiração real, além de reduções na precipitação. Um período com déficit de precipitação anormal é definido como uma seca meteorológica.

El niño-oscilação sul (ENSO): O termo *El Niño* foi inicialmente usado para descrever uma corrente de água quente que flui periodicamente ao longo da costa do Equador e do Peru, interrompendo a pesca local. Desde então, tornou-se identificado com o aquecimento do Oceano Pacífico tropical a leste da linha de data. Este evento oceânico está associado a uma flutuação de um padrão de pressão de superfície tropical e subtropical em escala global chamado de Oscilação Sul. Esse fenômeno acoplado atmosfera-oceano, com escalas de tempo preferidas de dois a cerca de sete anos, é conhecido como El Niño-Oscilação Sul (ENSO). É frequentemente medido pela diferença de anomalia de pressão superficial entre Tahiti e Darwin e/ou as temperaturas da superfície do mar na região central e Pacífico equatorial oriental. Durante um evento ENSO, os ventos alísios predominantes enfraquecem, reduzindo a ressurgência e alterando as correntes oceânicas de tal forma que as temperaturas da superfície do mar aquecem, enfraquecendo ainda mais os ventos alísios. Este fenômeno tem um grande impacto no vento, temperatura da superfície do mar e padrões de precipitação no Pacífico tropical. Tem efeitos climáticos em toda a região do Pacífico e em muitas outras partes do mundo, por meio de teleconexões globais. A fase fria do ENSO é chamada de *La niña*.

Segurança alimentar: O objetivo de um determinado país, ou da comunidade global como um todo, de manter um suprimento de alimentos adequado, estável e previsível. As medidas abrangem a salvaguarda da suficiência dos recursos alimentares para satisfazer a procura nacional de energia a preços competitivos e estáveis e a resiliência da oferta energética; permitindo o desenvolvimento e implantação de tecnologia.

Evidência: Dados e informações usados no processo científico para estabelecer descobertas. Neste relatório, o grau de evidência reflete a quantidade, qualidade e consistência das informações científicas/técnicas nas quais os autores principais estão baseando suas descobertas.

Evento climático extremo: Um evento climático extremo é um evento raro em um determinado local e época do ano. As definições de raro variam, mas um evento climático extremo normalmente seria tão ou mais raro que o percentil 10 ou 90 de uma função de densidade de probabilidade estimada a partir de observações. Por definição, as características do que é chamado de clima extremo podem variar de lugar para lugar em um sentido absoluto. Quando um padrão de clima extremo persiste por algum tempo, como uma estação, pode ser classificado

como um evento climático extremo, especialmente se produzir uma média ou total que seja extrema (por exemplo, seca ou chuvas fortes ao longo de uma estação).

Aquecimento global: Um aumento na temperatura média global da superfície (GMST) em média ao longo de um período de 30 anos, em relação a 1850-1900, a menos que especificado de outra forma. Para períodos inferiores a 30 anos, o aquecimento global refere-se à temperatura média estimada ao longo dos 30 anos centrada nesse período mais curto, contabilizando o impacto de quaisquer flutuações ou tendências de temperatura nesses 30 anos.

Gás de efeito estufa (GEE): Os gases de efeito estufa são aqueles constituintes gasosos da atmosfera, tanto naturais quanto antropogênicos, que absorvem e emitem radiação em comprimentos de onda específicos dentro do espectro de radiação terrestre emitida pela superfície da Terra, pela própria atmosfera e pelas nuvens. Esta propriedade causa o efeito estufa. Vapor de água (H₂O), dióxido de carbono (CO₂), óxido nitroso (N₂O), metano (CH₄) e ozônio (O₃) são os principais gases de efeito estufa na atmosfera terrestre. Além disso, há uma série de gases de efeito estufa inteiramente produzidos pelo homem na atmosfera, como os halocarbonos e outras substâncias contendo cloro e bromo, tratadas no Protocolo de Montreal. Além de CO₂, N₂O e CH₄, o Protocolo de Kyoto trata dos GEEs hexafluoreto de enxofre, hidrofluorcarbonos (HFCs) e perfluorcarbonos (PFC).

Produto Interno Bruto (PIB): A soma do valor acrescentado bruto, a preços de compra, por todos os produtores residentes e não residentes na economia, acrescido de quaisquer impostos e deduzido de quaisquer subsídios não incluídos no valor dos produtos num país ou numa região geográfica durante um determinado período, normalmente um ano. O PIB é calculado sem dedução de depreciação de ativos fabricados ou esgotamento e degradação de recursos naturais.

Perigo: A ocorrência potencial de um evento ou tendência física natural ou induzida pelo homem que pode causar perda de vidas, ferimentos ou outros impactos à saúde, bem como danos e perdas à propriedade, infraestrutura, meios de subsistência, prestação de serviços, ecossistemas e recursos ambientais.

Onda de calor: Um período de clima anormalmente quente. Ondas de calor e ondas de calor têm definições variadas e, em alguns casos, sobrepostas.

Ciclo hidrológico: O ciclo em que a água evapora dos oceanos e da superfície terrestre, é transportada sobre a Terra na circulação atmosférica como vapor d'água, condensa para formar

nuvens, precipita como chuva ou neve, que em terra pode ser interceptada por árvores e vegetação, potencialmente acumulada como neve ou gelo, fornece escoamento na superfície da terra, infiltra-se nos solos, recarrega as águas subterrâneas, descarrega em córregos, flui para os oceanos e, finalmente, evapora novamente do oceano ou da superfície terrestre. Os vários sistemas envolvidos no ciclo hidrológico são geralmente chamados de sistemas hidrológicos.

Impactos (consequências, resultados): As consequências dos riscos realizados nos sistemas naturais e humanos, onde os riscos resultam das interações de perigos relacionados ao clima (incluindo eventos climáticos e climáticos extremos), exposição e vulnerabilidade. Os impactos geralmente se referem a efeitos sobre vidas, meios de subsistência, saúde e bem-estar, ecossistemas e espécies, ativos econômicos, sociais e culturais, serviços (incluindo serviços ecossistêmicos) e infraestrutura. Os impactos podem ser referidos como consequências ou resultados e podem ser adversos ou benéficos.

Temperatura do ar da superfície terrestre: A temperatura do ar próximo à superfície sobre a terra, normalmente medida a 1,25-2 m acima do solo usando equipamento meteorológico padrão.

Uso da terra: O uso da terra refere-se ao total de arranjos, atividades e insumos realizados em um determinado tipo de cobertura da terra (um conjunto de ações humanas). O termo uso da terra também é usado no sentido dos propósitos sociais e econômicos para os quais a terra é administrada (por exemplo, pastagem, extração de madeira, conservação e moradia na cidade). Nos inventários nacionais de gases de efeito estufa, o uso da terra é classificado de acordo com as categorias de uso da terra do IPCC: terras florestais, terras agrícolas, pastagens, áreas úmidas, assentamentos, outros.

Mudança de uso da terra: A mudança de uso da terra envolve uma mudança de uma categoria de uso da terra para outra.

Probabilidade: A chance de um resultado específico ocorrer, onde isso pode ser estimado probabilisticamente.

Mitigação (das mudanças climáticas): Uma intervenção humana para reduzir as emissões ou aumentar os sumidouros de gases de efeito estufa. Observe que isso abrange as opções de remoção de dióxido de carbono.

Medidas de mitigação: Na política climática, as medidas de mitigação são tecnologias, processos ou práticas que contribuem para a mitigação, por exemplo, tecnologias de energia renovável (ER), processos de minimização de resíduos, práticas de transporte público.

Monitoramento e avaliação: Monitoramento e avaliação referem-se a mecanismos implementados em escala nacional e local para, respectivamente, monitorar e avaliar os esforços para reduzir as emissões de gases de efeito estufa e/ou adaptar-se aos impactos das mudanças climáticas com o objetivo de identificar, caracterizar e avaliar sistematicamente o progresso ao longo do tempo.

Políticas (para mitigação e adaptação às mudanças climáticas): As políticas são adotadas e/ou mandatadas por um governo - muitas vezes em conjunto com empresas e indústrias dentro de um único país, ou coletivamente com outros países - para acelerar as medidas de mitigação e adaptação. Exemplos de políticas são mecanismos de apoio ao fornecimento de energia renovável, impostos sobre carbono ou energia, padrões de eficiência de combustível para automóveis, etc.

Resiliência: A capacidade dos sistemas sociais, econômicos e ambientais de lidar com um evento perigoso, tendência ou distúrbio, respondendo ou reorganizando de maneira a manter sua função, identidade e estrutura essenciais, ao mesmo tempo em que mantém a capacidade de adaptação, aprendizado e transformação.

Risco: O potencial para consequências adversas onde algo de valor está em jogo e onde a ocorrência e o grau de um resultado são incertos. No contexto da avaliação do clima impactos, o termo risco é frequentemente usado para se referir ao potencial de consequências adversas de um perigo relacionado ao clima, ou de respostas de adaptação ou mitigação a tal perigo, sobre vidas, meios de subsistência, saúde e bem-estar, ecossistemas e espécies, aspectos econômicos, sociais e bens culturais, Serviços (incluindo serviços ecossistêmicos) e infraestrutura. O risco resulta da interação da vulnerabilidade (do sistema afetado), sua exposição ao longo do tempo (ao perigo), bem como o perigo (relacionado ao clima) e a probabilidade de sua ocorrência.

Gerenciamento de riscos: Planos, ações, estratégias ou políticas para reduzir a probabilidade e/ou consequências dos riscos ou para responder às consequências.

Cenário: Uma descrição plausível de como o futuro pode se desenvolver com base em um conjunto coerente e internamente consistente de suposições sobre as principais forças motrizes

(por exemplo, taxa de mudança tecnológica (TC), preços) e relacionamentos. Observe que os cenários não são previsões nem previsões, mas são usados para fornecer uma visão das implicações de desenvolvimentos e ações.

Sustentabilidade: Um processo dinâmico que garante a persistência dos sistemas naturais e humanos de forma equitativa.

Desenvolvimento sustentável: Desenvolvimento que atende às necessidades do presente sem comprometer a capacidade das gerações futuras de atender às suas próprias necessidades e equilibra as preocupações sociais, econômicas e ambientais.

Objetivos de Desenvolvimento Sustentável (ODS): As 17 metas globais de desenvolvimento para todos os países estabelecidas pelas Nações Unidas por meio de um processo participativo e elaboradas na Agenda 2030 para o Desenvolvimento Sustentável, incluindo acabar com a pobreza e a fome; garantir saúde e bem-estar, educação, igualdade de gênero, água potável e energia e trabalho decente; construir e garantir infraestrutura, cidades e consumo resilientes e sustentáveis; redução das desigualdades; proteger os ecossistemas terrestres e aquáticos; promover a paz, a justiça e as parcerias; e tomar medidas urgentes sobre as mudanças climáticas.

Transição: O processo de mudança de um estado ou condição para outro em um determinado período de tempo. A transição pode ser em indivíduos, empresas, cidades, regiões e nações, e pode ser baseada em mudanças incrementais ou transformadoras.

Incerteza: Um estado de conhecimento incompleto que pode resultar da falta de informação ou do desacordo sobre o que é conhecido ou mesmo cognoscível. Pode ter muitos tipos de fontes, desde imprecisão nos dados até conceitos ou terminologia definidos de forma ambígua, compreensão incompleta de processos críticos ou projeções incertas do comportamento humano. A incerteza pode, portanto, ser representada por medidas quantitativas (por exemplo, uma função de densidade de probabilidade) ou por declarações qualitativas (por exemplo, refletindo o julgamento de uma equipe de especialistas).

Vulnerabilidade: A propensão ou predisposição a ser adversamente afetada. A vulnerabilidade engloba uma variedade de conceitos e elementos, incluindo sensibilidade ou suscetibilidade a danos e falta de capacidade para lidar e se adaptar.