



**UNIVERSIDADE DO ESTADO DE MATO GROSSO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE
E BIOTECNOLOGIA - REDE BIONORTE**



**BALANÇO DE DIÓXIDO DE CARBONO ASSOCIADO A MUDANÇA
NO USO E COBERTURA DO SOLO NA AMAZÔNIA LEGAL
BRASILEIRA VIA SENSORIAMENTO REMOTO**

PATRÍCIA MONIQUE CRIVELARI DA COSTA

Sinop – MT

2023

PATRÍCIA MONIQUE CRIVELARI DA COSTA

**BALANÇO DE DIÓXIDO DE CARBONO ASSOCIADO A MUDANÇA
NO USO E COBERTURA DO SOLO NA AMAZÔNIA LEGAL
BRASILEIRA VIA SENSORIAMENTO REMOTO**

Doutorado no Programa de Pós-Graduação em Biodiversidade e Biotecnologia - Rede BIONORTE, da Universidade do Estado de Mato Grosso, como requisito parcial para a obtenção do Título de Doutor em Biodiversidade e Biotecnologia.

Orientador: Prof. Dr. Carlos Antonio da Silva Junior

Sinop – MT

08/2023

- C837b COSTA, Patricia Monique Crivelari da.
Balanço de Dióxido de Carbono Associado a Mudança no
Uso e Cobertura do Solo na Amazônia Legal Brasileira Via
Sensoriamento Remoto / Patricia Monique Crivelari da
Costa - Cuiabá, 2023.
94 f.; 30 cm. (ilustrações) Il. color. (sim)
- Trabalho de Conclusão de Curso (Tese/Doutorado) - Curso
de Pós-graduação Stricto Sensu (Doutorado) Rede em
Biodiversidade e Biotecnologia da Amazônia Legal: Rede
Bionorte, Instituto Nacional de Pesquisas do Pantanal Cuiabá e
Cidade Universitária Celso Campus Univers. de Cáceres., Pró-
Reitoria de Pesquisa e Pós-Graduação, Universidade do Estado
de Mato Grosso, 2023.
Orientador: Carlos Antonio da Silva Junior
1. Fluxo de Dióxido de Carbono. 2. Produção Primária
Bruta. 3. Google Earth Engine. 4. Modis. 5. Gosat. I. Patricia
Monique Crivelari da Costa. II. Balanço de Dióxido de Carbono
Associado a Mudança no Uso e Cobertura do Solo na Amazônia
Legal Brasileira Via Sensoriamento Remoto: .
CDU 536

PATRÍCIA MONIQUE CRIVELARI DA COSTA

**BALANÇO DE DIÓXIDO DE CARBONO ASSOCIADO A MUDANÇA
NO USO E COBERTURA DO SOLO NA AMAZÔNIA LEGAL
BRASILEIRA VIA SENSORIAMENTO REMOTO**

Tese de doutorado apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Biodiversidade e Biotecnologia - Rede BIONORTE, da Universidade do Estado de Mato Grosso, como requisito parcial para a obtenção do Título de Doutor em Biodiversidade e Biotecnologia.

Aprovada em 18/08/2023

Banca examinadora

Documento assinado digitalmente
 **CARLOS ANTONIO DA SILVA JUNIOR**
Data: 26/09/2023 14:55:44-0300
Verifique em <https://validar.iti.gov.br>

Prof. Doutor Carlos Antonio da Silva Junior (Orientador)
UNEMAT

Documento assinado digitalmente
 **EDSON EYJI SANO**
Data: 25/09/2023 14:55:50-0300
Verifique em <https://validar.iti.gov.br>

Prof. Doutor Edson Eyji Sano
EMBRAPA

Gabriel de Oliveira

Prof. Doutor Gabriel de Oliveira
University of South Alabama

Documento assinado digitalmente
 **RICARDO DAL AGNOL DA SILVA**
Data: 26/09/2023 12:08:04-0300
Verifique em <https://validar.iti.gov.br>

Doutor Ricardo Dal'Agnol da Silva
UCLA/NASA

Documento assinado digitalmente
 **DOMINGOS DE JESUS RODRIGUES**
Data: 26/09/2023 08:50:13-0300
Verifique em <https://validar.iti.gov.br>

Prof. Doutor Domingos de Jesus Rodrigues
UFMT

AGRADECIMENTOS

Agradeço primeiramente e sempre a Deus, por me dar condições de estar aqui onde estou hoje, pela condição financeira para bancar minhas sessões com psicólogo, psiquiatra, acupuntura e massagens, para aliviar as tensões, pressões, ansiedades, estresses e depressões do período. Realmente, Deus, obrigada pela Cris, Dr. Paulo, os tios Tiney e Naldo, realmente são os melhores no que fazem que já conheci!

Obrigada, Deus, por acalentar o coração de meus pais mesmo com tantas idas e vindas... eram tantos abraços de bem-vinda e despedida que chegava a apertar o coração ... principalmente o de Dona Joelma, minha mãe, professora e incentivadora do ensino e educação. Mulher guerreira que trabalhou três turnos só para me dar a educação que achava que eu merecia! E olha só onde estamos, né mamãe...

Obrigada, meu papai, Sr. Valdinei! Que sem o ensino médio completo me deu o maior e melhor suporte educacional que uma filha pode querer. Na sua motinha embaixo de Sol o dia todo, ele fez nossa base! Ainda estamos crescendo papai, não estou onde quero estar, mas o senhor me deu o suficiente para estar no caminho certo e em breve chegar lá ...

Obrigado ao programa Rede Bionorte, inicialmente com o Prof. João Carlos que praticamente me arrastou para dentro quando a “preguiça” acadêmica quase me atingiu ... Deu-me um projeto e acolheu-me aos seus trabalhos ... foi a ponte, o estopim ... para que eu pudesse crescer e ser grande como o grande e inesquecível Prof. Dr. Carlos Antônio da Silva Júnior (e poder pensar em ser um dia tão grande quanto ele!). Grande *big boss*, sensato e de currículo gigantesco... muito seletivo e (pouco) simpático. Obrigada, professor, por nos salvar, fazer-nos sair da casinha e do conforto, “sentar a bunda na cadeira” e ler (ler muito, muito mesmo), por nos ensinar a sermos cientistas de verdade! Obrigada por me aceitar e continuar me aceitando (mesmo quando sumia) como sua PRIMEIRA orientada oficial de doutorado e obrigada por não me demitir (nem por justa causa).

Ahh... abençoado seja o Prof. Tabajara por essa ponte, gratidão! Mesmo me desligando e depois me insistindo em continuar, esse homem foi incrível no programa, o “Severino” que fez tudo por nós e nos ajudou dos problemas que surgiam... (depois de algumas horas de conversa).

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa, e à Universidade do Estado de Mato Grosso (UNEMAT), pela estrutura, bem como o grupo de pesquisa Geotecnologia Aplicada em Agricultura e Floresta (GAAF).

Ao Luciano, pelos dados de GOSAT, que me ajudou demais, desemperrando o meu trabalho e ao Gustavo, que me ensinou a trabalhar com esses dados, através da análise de *hotspot*. À Tatiane, pela recepção na minha chegada a Sinop, pelas dicas imprescindíveis de sobrevivência no GAAF e pelos conselhos importantes sobre o *big boss*... À Edivânia, por me dar uma excelente temporada em sua casa.

Ao príncipe herdeiro Fernando R-O-S-S-I, por sua capacidade em nos fazer ganhar tempo, resolvendo nossos problemas em programação no *Google Earth Engine*, no R e no ArcGis. Ao José, por sua ligeireza em explicar o que estamos fazendo aqui computacionalmente, e fazer isso em tempos negativos, que nos economizava tempo de artigos lidos... À Cleyriane, João, Wendel, Ana, Betrielly, Samily e outros que fizeram desse laboratório mais divertido diante de tantas pressões.

A todos os familiares e amigos que caminharam comigo e me ajudaram nesta caminhada, bem como meu parceiro atual, Márcio, que me apoiou de todas as maneiras possíveis. Obrigada.

CRIVELARI COSTA, Patrícia Monique. **Balanço de dióxido de carbono associado a mudança no uso e cobertura do solo na Amazônia Legal brasileira via sensoriamento remoto**. 2023. 94 f. Tese (Doutorado em Biodiversidade e Biotecnologia) - Universidade do Estado de Mato Grosso, Sinop, 2023.

RESUMO

Na região Amazônica, encontra-se a maior floresta tropical do planeta que é responsável por absorver grandes quantidades de gás carbônico (CO₂) da atmosfera. No entanto, as mudanças no uso e cobertura do solo, especialmente devido ao desmatamento, têm contribuído para o aumento das emissões de gases de efeito estufa (GEE), principalmente o CO₂, colocando em risco terras indígenas (TI) e unidades de conservação (UC) na região. Portanto, o objetivo deste estudo foi detectar as mudanças nas emissões e remoções de CO₂ associadas às mudanças no uso e cobertura do solo na Amazônia Legal Brasileira (BLA) por meio da análise de imagens de satélite multiespectrais de 2009 a 2019. A BLA possui 5,02 M km² o que corresponde a 58,9% do território brasileiro. As variáveis usadas no estudo foram Produção Primária Bruta (GPP) e CO₂Flux que foram estimadas pelo sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) a bordo dos satélites Terra e Aqua, representando a absorção de carbono durante o processo de fotossíntese pela vegetação. A concentração atmosférica de CO₂ foi estimada a partir do satélite GOSAT. A floresta absorveu 211,05 TgC anualmente, mas devido à conversão parcial para outros usos do solo, a perda de 135.922,34 km² de área florestal resultou na absorção de 5,82 Tg a menos de C. As variáveis GPP e CO₂Flux mostraram o fluxo efetivo de carbono na BLA para a atmosfera, os quais foram fracamente correlacionados com a precipitação ($r = 0,19$ e $0,13$). A pastagem e a agricultura, que compreendem as principais conversões de terras, aumentaram 100.340,39 km² e absorveram 1,32 e 3,19 TgC a menos, e emitiram cerca de duas vezes mais que a floresta nessas áreas. As concentrações atmosféricas de CO₂ aumentaram de 2,2 para 2,8 ppm anualmente na BLA, com *hotspots* observados no sudeste da Amazônia, e a captura de CO₂ por GPP apresentou aumento significativo anual, principalmente após 2013, no norte e oeste da BLA. Este estudo traz maior compreensão da dinâmica do carbono e sua relação com o uso e cobertura do solo em um dos maiores reservatórios de carbono do mundo, a Amazônia. Tais resultados são importantes no cumprimento de acordos internacionais de redução das emissões de GEE, na conservação da biodiversidade e em outros serviços ecossistêmicos da região, como a preservação de etnias e línguas nativas, fauna e flora endêmicas.

Palavras-chave: Fluxo de dióxido de carbono; Produção primária bruta; *Google Earth Engine*; MODIS; GOSAT.

CRIVELARI COSTA, Patrícia Monique. **Carbon dioxide balance associated with land use and land cover change in Brazilian Legal Amazon via remote sensing**. 2023. 94 p. Thesis (PhD in Biodiversity and Biotechnology) - State University of Mato Grosso, Sinop, MT-Brazil, 2023.

ABSTRACT

The largest tropical forest on the planet is located in the Amazon region and is responsible for absorbing large amounts of carbon dioxide (CO₂) from the atmosphere. However, changes in land use and cover, especially due to deforestation, have contributed to an increase in greenhouse gas (GHG) emissions, especially the CO₂, and endangered indigenous lands and protected areas in the region. The objective of this study was to detect the changes in CO₂ emission and removals associated with land use and land cover changes in the Brazilian Legal Amazon (BLA) through the analysis of multispectral satellite images from 2009 to 2019. The BLA has 5.02 M km² and corresponding to 58.9% of the Brazilian territory. The Gross Primary Production (GPP) and CO₂Flux variables were estimated by *Moderate Resolution Imaging Spectroradiometer* (MODIS) sensor onboard Terra and Aqua satellite, representing the carbon absorption during the photosynthesis process by the vegetation. Atmospheric CO₂ concentration was estimated from GOSAT satellite. The forest absorbed 211.05 TgC annually but due to its partial conversion to other land uses, the loss of 135,922.34 km² of forest area resulted in 5.82 TgC less carbon being absorbed. The GPP and CO₂Flux variables showed the effective flux of carbon in the BLA to atmosphere which were weakly correlated with precipitation ($r = 0,19$ and $0,13$). Pasture and agriculture, which comprehend the main land conversions, increased 100,340.39 km² and absorbed 1.32 and 3.19 TgC less, and emitted close to twice more than forest in these areas. Atmospheric CO₂ concentrations increased from 2.2 to 2.8 ppm annually in BLA, with hotspots observed in the southeast Amazonia, and CO₂ capture by GPP showed an increase over the years, mainly after 2013, in the north and west of the BLA. This study brings to light the C dynamics as related to the land use and land cover in one of the biggest world C reservoirs, the Amazon, which is also important to fulfillment of international agreements signed by Brazil to reduce GHG emissions and for biodiversity conservation and other ecosystem services in the region, such as the preservation of ethnic groups, native languages, endemic fauna and flora.

Keywords: Carbon dioxide flux; Gross primary production; Google earth engine; MODIS; GOSAT.

LISTA DE FIGURAS

Figura 1 - Amazônia Legal brasileira e seus biomas, terras indígenas, unidades de conservação, rodovias federais e rios (COUTINHO, 2016; IBGE, 2020, 2021). Estados do Acre (AC), Amapá (AP), Amazonas (AM), Mato Grosso (MT), Maranhão (MA), Rondônia (RO), Roraima (RR), Tocantins (TO) e Pará (PA).....	31
Figura 2 - Classes do uso e cobertura do solo na BLA entre 2009-2019.	42
Figura 3 – Mudança no uso e cobertura do solo no distrito de Santo Antônio do Matupi, município de Manicoré - AM, para 2009 (A) e sua versão ampliada (C), e para 2019 (B) sua versão ampliada (D).....	44
Figura 4 – Produção primária bruta ($\text{gC m}^{-2} \text{ano}^{-1}$) na Amazônia Legal entre 2009 e 2019..	47
Figura 5 – Fluxo de dióxido de carbono ($\mu\text{mol m}^{-2} \text{s}^{-1}$) na Amazônia Legal entre 2009 e 2019.	48
Figura 6 – Hotspot para concentrações atmosféricas (XCO_2) recuperadas de dados GOSAT na Amazônia Legal entre 2009 e 2019.	49
Figura 7 - Precipitação anual (mm ano^{-1}) na Amazônia Legal entre 2009 e 2019.	50
Figura 8 – Histograma da frequência de distribuição dos dados de GPP, CO_2Flux e Chuva.	52
Figura 9 – <i>Boxplot</i> da mediana, quartis de 25% e 75%, e dados de <i>outliers</i> para classes (em ordem alfabética, CL, DBF, EBF, MF, GL, PW, SV, UBL, WB e WSB) das variáveis (a) GPP, (b) CO_2Flux e (c) Chuva, e por anos, para (d) GPP, (e) CO_2Flux e (f) Chuva.	53
Figura 10 – Análise de cluster entre as variáveis GPP, CO_2Flux e Chuva escaladas, nos diferentes uso e cobertura do solo. Florestas perenes de folhas largas (EBF); Floresta decíduas de folhas largas (DBF); Florestas mistas (MF); Savanas lenhosas (WSV); Cerrados (SV); Campos (GL); Pântanos ou pantanal (PW); Cultivos agrícolas (CL); Cidades ou área urbana (UBL); Corpos d’água (WB).....	55
Figura 11 – Gráfico de dispersão da distribuição e as correlações entre as variáveis GPP, CO_2Flux e Chuva nos diferentes uso e cobertura do solo. Os valores mostrados em cinza indicam a correlação geral, enquanto os valores coloridos indicam a correlação entre os uso e cobertura do solo. *, ** e ***: significativos a 5, 1 e 0,1% de probabilidade pelo teste t, respectivamente.	57
Figura 12 - Análise de componentes principais para as variáveis nos diferentes uso e cobertura do solo	58

LISTA DE TABELAS

Tabela 1 - Classificação Tipo 1 do produto MCD12Q1	33
Tabela 2 – Área, em km ² , das classes de uso e cobertura do solo da BLA entre 2009 e 2019.	41
Tabela 3 – <i>p-value</i> do teste multivariado de normalidade de Shapiro-Wilk não agrupado e agrupado por classes e anos para as variáveis GPP, CO ₂ Flux e Chuva.	51
Tabela 4 – Estatística descritiva dos dados de GPP, CO ₂ Flux e Chuva, para cada uso e cobertura do solo na Amazônia Legal, entre 2009 e 2019.	54
Tabela 5 – <i>p-value</i> para os testes de Mann-Kendall e Pettitt para as variáveis GPP, CO ₂ Flux e Chuva na BLA, agrupadas por uso e cobertura do solo.	59

LISTA DE ABREVIATURAS E SIGLAS

BN	Deserto ou Solo descoberto: pelo menos 60% da área é estéril sem vegetação (areia, rocha, solo) com menos de 10% de vegetação.
BLA	Amazônia Legal Brasileira, do inglês <i>Brazilian Legal Amazon</i>
CL	Cultivo agrícola: pelo menos 60% da área é área cultivada.
CS	Cerradão: dominados por plantas perenes lenhosas (1-2m de altura) > 60% de cobertura.
DBF	Florestas decíduas de folha larga: dominadas por árvores decíduas de folha larga (copa > 2m). Cobertura de árvores > 60%.
DNF	Florestas decíduas de folha estreita: dominadas por árvores decíduas de folha agulha (copa > 2m). Cobertura de árvores > 60%.
EBF	Florestas perenes de folha larga: dominadas por árvores perenes de folha larga e palmeiras (copa > 2m). Cobertura de árvores > 60%.
ENF	Florestas perenes de folha estreita: dominadas por árvores coníferas perenes (copa > 2m). Cobertura de árvores > 60%.
GEE	Gases de efeito estufa
GL	Campos ou Pastagem: dominadas por plantas anuais herbáceas (<2m).
GPP	Produtividade Primária Bruta, do inglês <i>Gross Primary Productivity</i>
MF	Florestas mistas: dominadas por tipo de árvore nem decídua nem perene (40-60% de cada) (copa > 2m). Cobertura de árvores > 60%.
NVM	Mosaicos de cultivo/vegetação natural: mosaicos de cultivo em pequena escala 40-60% com árvore natural, arbusto ou vegetação herbácea.
OS	Cerrado denso: dominados por plantas perenes lenhosas (altura de 1-2m) com cobertura de 10-60%.
PSI	Neve e gelo permanentes: pelo menos 60% da área é coberta por neve e gelo por pelo menos 10 meses do ano.
PW	Pântano: terras permanentemente inundadas com 30-60% de cobertura de água e > 10% de cobertura vegetal.
SR	Sensoriamento Remoto
SV	Cerrado ralo: cobertura arbórea de 10-30% (copa > 2m).
TI	Terras Indígenas
UC	Unidades de conservação
UBL	Área urbana /Terrenos Urbanos e Construídos: pelo menos 30% da superfície impermeável incluindo materiais de construção, asfalto e veículos.
WB	Corpos d'água: pelo menos 60% da área é coberta por corpos d'água permanentes.
WSV	Cerrado típico: cobertura arbórea de 30-60% (copa > 2m).
XCO₂	Concentração atmosférica de dióxido de carbono

SUMÁRIO

1. INTRODUÇÃO	11
1.1 HIPÓTESES	14
1.2 OBJETIVO GERAL	15
1.3 OBJETIVOS ESPECÍFICOS	15
2. REVISÃO BIBLIOGRÁFICA	16
2.1 EMISSÃO DE GASES DE EFEITO ESTUFA	16
2.2 USO E COBERTURA DO SOLO NA AMAZÔNIA LEGAL BRASILEIRA	19
2.3 TERRAS INDÍGENAS (TI) E UNIDADES DE CONSERVAÇÃO (UC) DA AMAZONIA LEGAL BRASILEIRA	20
2.4 O CARBONO NA BIOSFERA E ATMOSFERA	22
2.4.1. Produção Primária Bruta (GPP)	22
2.4.2. Concentrações Atmosféricas de CO₂ (XCO₂)	24
2.4.3. Fluxo de Dióxido de Carbono (CO₂Flux)	26
2.5 PRECIPITAÇÕES NA AMAZÔNIA LEGAL BRASILEIRA	28
3. MATERIAL E MÉTODOS	31
3.1 ÁREA DE ESTUDO	31
3.2 DADOS	32
3.2.1 Dados de uso e cobertura do solo	32
3.2.2 Dados de Produção Primária Bruta (GPP)	34
3.2.3 Fluxo de dióxido de carbono (CO₂Flux)	35
3.2.4 Concentração atmosférica de CO₂ (XCO₂)	36
3.2.5 Dados de precipitação	36
3.3 ANÁLISES	37
3.3.1 Mudança de uso e cobertura do solo de 2009 a 2019	37
3.3.2 Agrupamento espacial de carbono atmosférico	37
3.3.3 Teste de normalidade	38
3.3.4 Variabilidade do fluxo de carbono de classes de uso e cobertura do solo ...	38
3.3.5 Análise de Cluster	39
3.3.6 Análise de tendência	40
4. RESULTADOS	41
4.1 MUDANÇAS NO USO E COBERTURA DO SOLO	41
4.2 VARIABILIDADE ESPACIAL DO CARBONO	46
4.3 ANÁLISE ESTATÍSTICA	51
5. DISCUSSÃO	61
5.1 O EFEITO DAS MUDANÇAS NO USO E COBERTURA DO SOLO EM TERRAS INDÍGENAS, ÁREAS PROTEGIDAS E OUTRAS ÁREAS IMPORTANTES DE CONSERVAÇÃO	61
5.2 O FLUXO ESPACIAL DE CARBONO NA AMAZÔNIA LEGAL	64
5.3 ANÁLISE DE CARBONO POR USO E COBERTURA DO SOLO	66
6. CONCLUSÕES	72
7. CONSIDERAÇÕES FINAIS E PERSPECTIVAS FUTURAS	73
REFERÊNCIAS BIBLIOGRÁFICAS	74
ANEXOS	95

1. INTRODUÇÃO

Os ecossistemas florestais intactos aumentam a resiliência em relação às mudanças climáticas e conservam a biodiversidade (WATSON *et al.*, 2018). A Amazônia Legal Brasileira (BLA), delimitada em consonância ao Art. 2º da Lei Complementar nº 124, de 03 de janeiro de 2007 (BRASIL, 2007), com uma superfície de 5,02 milhões de km², correspondente a 58,9% do território brasileiro (IBGE, 2021). A BLA possui a maior área de floresta tropical úmida, maior biodiversidade, maior quantidade de biomassa aérea e uma das maiores fontes de recursos minerais e biológicos do mundo (AMIGO, 2020; ARAGÃO *et al.*, 2014; QIN *et al.*, 2021). Nela abriga o maior bioma brasileiro, o amazônico (IBGE, 2021).

Entre os serviços ambientais fornecidos pela floresta amazônica, está a remoção e armazenamento de carbono da atmosfera por meio do gás carbônico (CO₂), providenciado pela produção primária bruta (GPP) (ALMEIDA *et al.*, 2018; CHAGAS *et al.*, 2019; ZHANG *et al.*, 2017a). Por exemplo, um sumidouro florestal de $2,4 \pm 0,4$ Pg C ano⁻¹ foi estimado globalmente e 262,1 Pg C foram estocados em biomassa vegetal na América tropical (PAN *et al.*, 2011).

O GPP refere-se à absorção de CO₂ durante o processo de fotossíntese (RUNNING; ZHAO, 2019; WANG *et al.*, 2017; YAN *et al.*, 2019). A análise das anomalias nos valores do GPP determina o impacto das mudanças na absorção e nas emissões de carbono (DA SILVA JUNIOR *et al.*, 2022). É possível e necessário estimar com precisão suas variações temporais e espaciais para entender as funções do ecossistema em resposta ao clima e mudanças no uso e cobertura do solo (LIN *et al.*, 2017; WAGLE *et al.*, 2016). Esses processos desempenham um papel importante no balanço de C entre a atmosfera e a biosfera (WANG *et al.*, 2017; YAN *et al.*, 2019), bem como nas modificações em resposta às mudanças climáticas (ALVES *et al.*, 2017; BERENQUER *et al.*, 2021; FERREIRA BARBOSA *et al.*, 2021; LIN *et al.*, 2017; WAGLE *et al.*, 2016). Essas modificações estão relacionadas principalmente à perda florestal, induzida pelo desmatamento, que contribui para as emissões de gases de efeito estufa (GEE), com isso agravando o aquecimento global (AMARAL *et al.*, 2019; OLIVEIRA *et al.*, 2020; RAMMIG; LAPOLA, 2021).

As Terras Indígenas (TI), áreas destinadas à população indígena, e as Unidades de Conservação (UC), áreas destinadas à conservação ambiental, da BLA representam 43% da área total e cobrem cerca de metade da área florestal total da região (QIN *et al.*, 2023). Elas são importantes na conservação da floresta e da biodiversidade e na mitigação do clima da BLA, pois atuam como “escudos” contra o desmatamento (BEGOTTI; PERES, 2019;

CRISOSTOMO *et al.*, 2015; QIN *et al.*, 2023). No entanto, a conservação florestal em TI/UC tem enfrentado ameaças crescentes de leis e regulamentos ambientais afrouxados, mudanças nas políticas governamentais e desenvolvimento econômico maciço (BEGOTTI; PERES, 2019; LIMA *et al.*, 2020; SILVEIRA *et al.*, 2018). Na BLA, 75% dos desmatamentos ocorreram em faixas ao longo das rodovias asfaltadas, a maioria próximas de TI e UC, induzindo a perdas florestais devido a diferentes mudanças no uso e cobertura do solo (LIMA *et al.*, 2020, 2022). A pavimentação das rodovias Belém-Brasília (BR-010) e Cuiabá-Porto Velho (BR-364) são exemplos que originaram o chamado “Arco do Desmatamento” (PERES, 2023; WWF, 2023).

O aumento das emissões de C, especialmente na forma de CO₂, as mudanças no uso e cobertura do solo e a pressão antrópica são os principais fatores da degradação de florestas tropicais, como a Amazônia, que levam a graves perdas de sumidouros de C (BARLOW *et al.*, 2020; BULLOCK *et al.*, 2020; RAMMIG; LAPOLA, 2021; SILVA JUNIOR *et al.*, 2021). As mudanças no uso e cobertura do solo causadas por atividades antrópicas alteraram substancialmente a ciclagem do C, contribuindo para o aumento da concentração atmosférica de CO₂ (XCO₂), entre outros gases causadores do efeito estufa, que é a principal causa do aquecimento global e das mudanças climáticas (ROSSI *et al.*, 2022). A mudança de uso do solo em clima tropical teve $1,1 \pm 0,7$ Pg C de emissões de C terrestre entre 2000-2007 (PAN *et al.*, 2011). A avaliação histórica das mudanças no uso e cobertura do solo é importante para a gestão de recursos naturais e o desenvolvimento de políticas sustentáveis, pois fornece *insights* sobre a interação entre o meio ambiente e os seres humanos naquela determinada região, evitando a degradação ambiental adicional (LOVEJOY; NOBRE, 2018, 2019).

As técnicas de sensoriamento remoto (SR) são frequentemente usadas para melhor compreensão das mudanças no uso e cobertura do solo, pois reduzem o custo e o tempo para detectar a degradação ambiental (ALSHARI; GAWALI, 2021; GHOSH; SHARMA; JOSHI, 2014), o clima e os fluxos de C, conforme amplamente coberto na literatura recente (ALVES *et al.*, 2017; DE OLIVEIRA-JÚNIOR *et al.*, 2021; DELLA-SILVA *et al.*, 2022; FERREIRA BARBOSA *et al.*, 2021; RAJU *et al.*, 2023; ROSSI *et al.*, 2022; SILVA *et al.*, 2023). O SR foi recentemente aplicado para atualizar os limites entre os biomas Cerrado-Amazônicos brasileiros devido a mudanças no uso e cobertura do solo, por meio de índices de vegetação, tais como GPP e fluxos de CO₂ (CO₂Flux), com isso, permitindo o desenvolvimento de políticas públicas para conter o desmatamento e a degradação por atividades antrópicas (SILVA JUNIOR *et al.*, 2019a). Além disso, o SR foi crucial em ajudar a desvendar o papel vital e os avanços substanciais das TI e UC na conservação da Amazônia, bem como os riscos do recente

enfraquecimento das políticas florestais no Brasil (MATAVELI; DE OLIVEIRA, 2022; QIN *et al.*, 2023).

Estudos têm mostrado que 40% de desmatamento na Amazônia seria suficiente para causar diminuição das chuvas e prolongar a estação seca, com uma mudança para a vegetação de savana no leste (E) e que 20-25% do desmatamento seria o ponto de inflexão para o sistema amazônico mudar para ecossistemas não florestais na maior parte do centro, sul e leste da Amazônia (LOVEJOY; NOBRE, 2018, 2019; SMITH *et al.*, 2023; STARK *et al.*, 2020). Nesse sentido, espera-se que as mudanças nas emissões de CO₂ e remoções induzidas por mudanças de uso e cobertura do solo na BLA tenham se intensificado ao longo dos últimos anos e possam ser identificadas e quantificadas por meio de imagens *Moderate Resolution Imaging Spectroradiometer* (MODIS) e modelos matemáticos. Logo, nesse estudo, foi investigada a relação entre mudanças de uso e cobertura do solo, GPP, CO₂Flux, XCO₂ e precipitação na BLA de 2009 a 2019. A investigação da perda ou ganho da capacidade de absorção de C dessas áreas pode facilitar decisões ecológicas e sustentáveis a fim de preservar a BLA e os reservatórios de C na região Amazônica.

1.1 HIPÓTESES

As emissões induzidas pela mudança do uso e cobertura do solo na Amazônia Legal Brasileira podem ser identificadas e quantificadas por meio de imagens multiespectrais do sensor MODIS e modelos matemáticos?

Há uma relação espacial e/ou temporal entre o uso e cobertura do solo e as variáveis ambientais (produção primária bruta, concentrações atmosféricas de CO₂, o fluxo de carbono) e climáticas (precipitação) na Amazônia Legal que influenciem o aumento ou redução do CO₂?

Existe uma tendência nas variáveis produção primária bruta, concentrações atmosféricas de CO₂, fluxo de C e precipitações na Amazônia Legal Brasileira que estão relacionados com as mudanças do uso e cobertura do solo, ciclos *El Niño* e *La Niña* e precipitações?

1.2 OBJETIVO GERAL

Estimar as emissões e remoções de CO₂ e relacionar com as mudanças do uso e cobertura do solo na Amazônia Legal brasileira (BLA) por meio de imagens multiespectrais do sensor MODIS no período 2009-2019.

1.3 OBJETIVOS ESPECÍFICOS

- Avaliar as mudanças de uso e cobertura do solo entre os anos de 2009 e 2019 por meio do produto MCD12Q1 versão 06 do sensor MODIS;
- Quantificar as emissões e remoções de CO₂ induzidas pela mudança do uso e cobertura do solo na BLA ao longo dos anos;
- Avaliar a produção primária bruta (GPP), entre os anos de 2009 e 2019, pelos produtos MOD e MYD17A2, na BLA;
- Estimar as concentrações de dióxido de carbono (XCO₂) e verificar os pontos quentes e frios das distribuições globais de frações molares de ar seco médias da coluna de CO₂ da BLA no período pelo GOSAT-2 FTS-2;
- Medir a eficiência do processo de absorção de C relacionado à vegetação da BLA, com o índice CO₂Flux, por meio do produto MOD09A1, entre 2009 e 2019;
- Averiguar as regularidades da precipitação ao longo da série temporal (2009-2019) da BLA com o conjunto de dados *Climate Hazards Group InfraRed Precipitation with Station Data* (CHIRPS);
- Analisar as relações dos ciclos *El Niño* e *La Niña* na dinâmica de C e no uso e cobertura do solo na BLA;
- Verificar a existência de tendências ao longo da série temporal (2009-2019) de cada variável com os testes de Mann-Kendall e Pettitt; e,
- Verificar, nas variáveis, os grupos que minimizam a dissimilaridade ou minimizam somas totais de quadrados, pela análise estatística de cluster, considerando a distância Euclidiana e o método hierárquico de Ward.

2. REVISÃO BIBLIOGRÁFICA

2.1 EMISSÃO DE GASES DE EFEITO ESTUFA

As emissões de gases de efeito estufa (GEE) globais por diversas fontes cresceram de forma excessiva até 2008 (FRIEDLINGSTEIN *et al.*, 2010). Em 2009, as emissões foram as mais altas da história humana, de $8,4 \pm 0,5$ Pg C ano⁻¹, apesar da aparente queda de 1,3% no GEE (BP, 2010), ocasionando a busca por estratégias que proporcionassem a redução desses gases (CARVALHO *et al.*, 2010).

As mudanças no uso e cobertura do solo (LULC - *Land Use and Land Cover*) em países tropicais contribuem significativamente para as emissões de GEE e desempenham um papel importante na mudança do clima global (LE QUÉRÉ *et al.*, 2015). Emissões globais decorrentes de mudanças no LULC foram de $1,1 \pm 0,7$ Pg C ano⁻¹ para 2000 a 2009, relativamente menor que em duas décadas atrás, de $1,5 \pm 0,7$ Pg C ano⁻¹ (1990), mas, apenas no ano de 2010 esta mesma fonte emitiu sozinha o valor de $0,9 \pm 0,7$ Pg C ano⁻¹ globalmente (FRIEDLINGSTEIN *et al.*, 2010). Em 2015, altas emissões de carbono, entre 0,504 e 0,989 Pg C ano⁻¹, ocorreram exclusivamente na Amazônia, também devido a mudança no LULC (DA SILVA JUNIOR *et al.*, 2022). A emissão por desmatamento na América tropical foi a que representou maiores emissões de C dentre as regiões tropicais globais, de 1.51 e 1.37 Pg C ano⁻¹ nos períodos de 1990 a 1999 e de 2000 a 2007, respectivamente (HUI *et al.*, 2015).

Reduzir as emissões resultantes da mudança de uso e cobertura do solo é o principal objetivo das nações amazônicas, principalmente em relação às taxas de desmatamento (ARAGÃO *et al.*, 2018; SCHIELEIN; BÖRNER, 2018; SILVA *et al.*, 2020b). Apesar de estas taxas terem diminuído na Amazônia até meados de 2012, devido às melhorias em relação a governança, monitoramento e estrutura jurídica (ARIMA *et al.*, 2014; INPE, 2021), no Brasil, o cenário político atual tem induzido à intensificação desses processos em decorrência de mudanças significativas em leis, políticas e regulamentações ambientais (LIMA *et al.*, 2020), que têm favorecido o desmatamento e a expansão das atividades agrícolas nas áreas próximas a floresta (AMIGO, 2020; CARDIL *et al.*, 2020; OLIVEIRA *et al.*, 2020; SCHIELEIN; BÖRNER, 2018).

Considerando a Amazônia Legal, 2012 foi o ano com menor taxa de desmatamento, enquanto 2004 foi o ano com maior taxa. Nesse período, mais de 160 mil km² foram desmatados (FERREIRA BARBOSA *et al.*, 2021). Os níveis estimados de emissão de CO₂ da Amazônia

brasileira diminuíram significativamente com uma taxa de $0,131 \pm 0,015 \text{ Pg CO}_2 \text{ ano}^{-1}$ de 2003 a 2012, mas logo voltaram a aumentar (LIMA *et al.*, 2020). Com isso, na Amazônia Legal, a conversão de florestas para pastagens e terras agrícolas tiveram emissões de 0,169 (2003/2004), 0,276 (2007/2008), 0,063 (2009/2010), 0,341 (2010/2011), 0,071 (2013) e 0,195 (2015) Pg C ano^{-1} (FERREIRA BARBOSA *et al.*, 2021). O Pará foi o estado mais desmatado (62.778 km^2), seguido por Mato Grosso (43.065 km^2) e Rondônia (22.279 km^2) no período de 2004 a 2009 (FERREIRA BARBOSA *et al.*, 2021).

Em 2015, o Brasil havia alcançado uma redução de 66% nas taxas de desmatamento na Amazônia ($6.207 \text{ km}^2 \text{ ano}^{-1}$) em comparação com os últimos anos anteriores ($18.439 \text{ km}^2 \text{ ano}^{-1}$) (INPE-PRODES, 2016). Essa conquista seguiu um conjunto de ações da sociedade civil, econômicas e de políticas públicas, com destaque para o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia (PPCDAm), implementado em 2004 pelo governo brasileiro com três fases (2004–2008, 2009–2011 e 2012–2015) com o objetivo de reduzir continuamente o desmatamento ilegal e estabelecer um modelo de desenvolvimento sustentável para a Amazônia (MINISTÉRIO DO MEIO AMBIENTE, 2013).

A preocupação com a Floresta Amazônica e principalmente com sua degradação tem aumentado estudos sobre a monitoração das emissões induzidas pela mudança no LULC (INPE, 2021; SILVA JUNIOR *et al.*, 2021). Estudos baseado na temática LULC são importantes na gestão dos recursos naturais e no desenvolvimento sustentável, pois indicam a interação entre o meio ambiente e os seres humanos naquela região (AL BALASMEH; KARMAKER, 2020; GILLANDERS *et al.*, 2008), dado que diversas atividades humanas estão relacionadas à terra e a mudança nas necessidades humanas modifica significativamente as características do uso do solo (BUCAŁA, 2014).

Em relação às discussões atuais sobre mudanças climáticas, a Amazônia é de especial interesse por ser um sumidouro de carbono (C) e abrigar uma grande biodiversidade, porém é ameaçada pelo desmatamento e pelo fogo (DA SILVA JUNIOR *et al.*, 2022). A perda florestal por meio do desmatamento e da queima de biomassa contribui para as emissões de GEE agravando o aquecimento climático (AMARAL *et al.*, 2019; OLIVEIRA *et al.*, 2020).

O Brasil é um dos países mais afetados pela mudança no LULC, principalmente pela ocorrência de desmatamento e consequente incêndios florestais para transformações em terras agrícolas, por ser o maior produtor mundial de soja e importante exportador de grãos (ROSSI; SANTOS, 2020). Em comparação com as florestas intactas, as florestas modificadas pelo homem são caracterizadas por maior abertura do dossel, maiores estoques de material morto, microclima mais seco e espécies com menor densidade de madeira (BAKER *et al.*, 2004).

Estes ecossistemas naturais intocados pelo impacto humano, ou florestas primárias, têm várias premissas que as distinguem das florestas secundárias ou perturbadas, como a integridade ecológica, pois não foram drasticamente alteradas por atividades humanas, como desmatamento, exploração madeireira intensiva ou agricultura; a diversidade biológica, que abrigam uma ampla diversidade de espécies de plantas, animais, insetos e micro-organismos; os ciclos naturais, com ciclos naturais de crescimento, reprodução e morte das árvores, bem como processos naturais de regeneração; a baixa intervenção humana, com consequente estabilidade ecológica, que servem como importantes fontes de abrigo, alimento e reprodução para inúmeras espécies, incluindo aquelas em risco de extinção; o armazenamento de Carbono, capturando CO₂ da atmosfera e armazenando-o na biomassa das árvores e no solo, ajudando assim na mitigação das mudanças climáticas; e um grande valor cultural e científico, pois são fontes ricas de pesquisa científica (WATSON *et al.*, 2018).

Preservar estas florestas primárias é essencial para manter a saúde do planeta, para a biodiversidade e para mitigar as mudanças climáticas, razão pela qual a conservação dessas áreas é uma prioridade para muitos esforços de conservação ambiental em todo o mundo. O alto número de desmatamento, focos de incêndio e áreas queimadas em estados como o Mato Grosso e o Pará pode estar ligado ao fato de grande parte do território já ter sido desmatado e ao tamanho desses estados, os quais compõem o chamado "Arco do Desmatamento" - região que sofre com a expansão agropecuária (PERES, 2023; QIN *et al.*, 2023). Em estados como o Mato Grosso, que já sofreu muito com o desmatamento e ainda possui uma grande área de Cerrado, a alta incidência de queimadas é preocupante (FERREIRA BARBOSA *et al.*, 2021).

Após perturbações, como desmatamento, incêndios florestais ou agricultura anterior, as florestas secundárias aparecem e são imprescindíveis no processo de regeneração natural. Estas florestas têm como vantagem o crescimento rápido, devido à maior disponibilidade de luz e nutrientes nas áreas perturbadas; os ciclos de sucessão, com diferentes espécies de plantas e árvores dominando ao longo do tempo, o que pode resultar em mudanças na composição da vegetação; a captura de carbono, com potencial para capturar e armazenar carbono, maior em relação às florestas primárias, contribuindo para a mitigação das mudanças climáticas (FERREIRA BARBOSA *et al.*, 2021; HEINRICH *et al.*, 2021).

No entanto, mesmo deixando estas áreas perturbadas regenerar, é preciso atenção e um manejo adequado, pois estas florestas apresentam maior suscetibilidade a distúrbios, devido à sua estrutura e composição mais jovens, podem ser mais suscetíveis a distúrbios, como pragas e incêndios florestais. As perturbações reduzem as taxas de regeneração em 8–55% e o estoque de carbono florestal secundário pode ser 8% maior se for evitado incêndios e desmatamentos

repetidos. A manutenção da área de floresta secundária na Amazônia tem o potencial de acumular aproximadamente $19,0 \text{ Tg C ano}^{-1}$ até 2030, contribuindo com 5,5% para a meta líquida de redução de emissões do Brasil para 2030 (HEINRICH *et al.*, 2021).

2.2 USO E COBERTURA DO SOLO NA AMAZÔNIA LEGAL BRASILEIRA

Em virtude de mudanças no uso e cobertura do solo em países tropicais contribuirão para as emissões de GEE (LE QUÉRÉ *et al.*, 2015), estudos dessas mudanças na Amazônia Legal podem representar grande incumbência na alteração do clima global. No norte da Amazônia, especificamente em Roraima, são registrados mais focos de incêndio no período mais úmido, enquanto os estados de Mato Grosso, Acre, Tocantins e Pará concentram mais queimadas e desmatamentos no período mais seco (FERREIRA BARBOSA *et al.*, 2021). As áreas com maior risco de incêndio são as que apresentam maior fragmentação das florestas e próximas a grandes estradas, áreas de pastagem, agricultura e regiões de cerrado (DA SILVA JÚNIOR *et al.*, 2019; ZHANG *et al.*, 2017b).

Da floresta amazônica meridional, a vegetação florestal representava 63,3% em 2021, enquanto os outros tipos de cobertura do solo correspondiam a savana, pastagem e lavoura, distribuídos principalmente na margem da região sul da Amazônia (ZHANG *et al.*, 2021a).

A classificação de LULC é frequentemente realizada por técnicas de sensoriamento remoto devido aos menores dispêndios monetários e tempo gasto (GHOSH; SHARMA; JOSHI, 2014), quando comparados com a classificação com base em dados terrestres, que é mais demorado e pode não ser completamente preciso (ALSHARI; GAWALI, 2021). Atualmente, um dos sensores mais utilizados para o uso e cobertura do solo é o sensor de Imagem por Espectrorradiometria de Resolução Moderada (MODIS - *Moderate-Resolution Imaging Spectroradiometer*). As imagens MODIS são referenciadas geograficamente e corrigidas para efeitos atmosféricos, como aerossóis e nuvens, e são distribuídos gratuitamente. Seus produtos são comumente usados para detecção mudanças de agentes antrópicos e naturais na cobertura do solo e fenologia vegetal (BEDIA *et al.*, 2015; FAJARDO; GUNDALE, 2015) e monitoramento da dinâmica espaço-temporal dos biomas (ADAMI *et al.*, 2008).

Outras aplicações do sensor MODIS incluem a detecção de incêndios (HUESCA *et al.*, 2009), monitoramento dinâmico de rios (KEESSTRA *et al.*, 2014), estimativa de propriedades biofísicas da superfície do solo (WANG *et al.*, 2016) e uso e cobertura do solo (CAÚLA *et al.*, 2017). Um desses produtos é o MCD12Q1, que fornece classificação anual de LULC a partir

de 2001. A resolução temporal é de 32 dias, correspondendo a dois ciclos orbitais completos (SULLA-MENASHE; FRIEDL, 2018).

As classes de LULC são atribuídas processando o banco de dados, por meio de agrupamentos por árvore de decisão e classificadores de rede neural artificial (RNA) treinados pelos dados do local, a cada 32 dias. Para reduzir a sobrecarga computacional e aumentar a flexibilidade, a classificação procede por continentes. Ela contém seis esquemas de classificação diferentes que descrevem as propriedades de cobertura da superfície derivadas de observações do sensor MODIS ao longo de um ano. O primeiro esquema de cobertura de superfície identifica 17 classes definidas pelo Programa Internacional de Geosfera da Biosfera (IGBP), que inclui 11 classes de vegetação natural, 3 classes de parcelas urbanizadas e 3 classes de solo não vegetado.

Estudos relatam alta precisão na classificação de LULC como o produto MCD12Q1, principalmente para classes mais estáveis, como corpos d'água e vegetação florestal (AHMAD *et al.*, 2022; BROWN *et al.*, 2022; CAÚLA *et al.*, 2017; HE *et al.*, 2022; SILVA *et al.*, 2023). No entanto, a resolução espacial grosseira do produto MCD12Q1, de 500 metros (SULLA-MENASHE; FRIEDL, 2018), restringe a identificação de pequenas áreas de lavouras, pastagens e corpos d'água, o que gera incertezas na estimativa do GPP.

A confusão entre as classes de LULC é responsável por incertezas, principalmente quando coberturas vegetais com alta eficiência fotossintética (florestas) são confundidas com de baixa eficiência (lavoura ou pastagem) ou vice-versa. Outro erro comum identificado no MCD12Q1 é a classificação como savanas em campos antrópicos ou áreas de cultivo e algumas pequenas áreas de pastagens e lavouras que nem sempre são classificadas devido à resolução espacial limitada, superestimando a extensão de floresta (ALMEIDA *et al.*, 2018).

2.3 TERRAS INDÍGENAS (TI) E UNIDADES DE CONSERVAÇÃO (UC) DA AMAZONIA LEGAL BRASILEIRA

Os conflitos entre conservação florestal e desenvolvimento socioeconômico na Amazônia Legal persistem, mas variam ao longo dos anos. A conservação florestal em TI/UC tem enfrentado ameaças crescentes de leis e regulamentos ambientais afrouxados, mudanças nas políticas governamentais e desenvolvimento econômico acelerado (BEGOTTI; PERES, 2019; SILVEIRA *et al.*, 2018), especialmente após 2012 no Brasil.

Desde 2000, os territórios indígenas (TI) e as áreas protegidas (UC) na Amazônia Legal aumentaram substancialmente e até 2013 representavam 43% da área total de terra e cobriam

cerca de metade da área total de floresta da região, representando papéis importantes na conservação da floresta e da biodiversidade e na mitigação do clima (QIN *et al.*, 2023).

As taxas de desmatamento de UC são até dez vezes menores que em áreas sem proteção ambiental. Isso porque as UC geralmente estão localizadas em áreas remotas e possuem maior cobertura florestal e menor pressão de desmatamento em comparação com UC e TI de uso sustentável ou as áreas sem proteção ambiental, que costumam ter alta pressão de desmatamento (QIN *et al.*, 2023).

O número e área de TI/UC na Amazônia Legal aumentou de 0,2 M ha, em 1980, para 115 M ha, em 2016. Em 2000, o Sistema Nacional de Áreas Protegidas do Brasil foi oficialmente estabelecido para expandir as UCs e melhor geri-las para a conservação das florestas. A área das UC nacionais aumentou de 9 M ha, em 1980, para 62 M ha, em 2008 e 66 M ha em 2018. A área das UCs estaduais aumentou para 56 M ha, em 2007, e 60 M ha em 2018. Quando somadas, a área total de TI/UC aumentou substancialmente de 10 M ha, em 1980, para 126 M ha, em 2000, e 241 M ha, em 2018. Os números de TI e UC também tiveram mudanças semelhantes ao longo do tempo e aumentaram substancialmente de 227 e 165, em 2000, para 387 e 357, em 2018, com aumento florestal de 55 e 150%, respectivamente (QIN *et al.*, 2023).

A maioria das TI/UC são cobertas por florestas e seu aumento fortalece substancialmente a conservação florestal. Em 2018, estas terras cobriam 206 M ha de floresta, representando 52% da área total de florestas em 2000, o que mostra claramente a importância das TI/UC para a conservação da floresta (QIN *et al.*, 2023).

As perdas anuais de área florestal em 2005, 2007, 2010 e 2015 foram substancialmente maiores do que nos anos anteriores (QIN *et al.*, 2023), pois foram caracterizados por fortes eventos de *El Niño*, que provocam alta temperatura do ar ou seca severa (FERREIRA BARBOSA *et al.*, 2021). A perda anual bruta de área florestal em 2013 foi menor durante 2000-2021, pois o ano de 2013 foi um ano com alta temperatura do ar sem um evento *El Niño* ou Oscilação Multidecadal do Atlântico (QIN *et al.*, 2023).

Desconsiderando-se anos de distúrbios (2010, 2013 e 2015), foi observado que aumentou a perda de área florestal em 2011–2014, diminuiu a perda de área florestal em 2016–2018 e aumentou a perda de área florestal em 2019–2021 (QIN *et al.*, 2023). Em 2018-2021, as taxas anuais de perda de área bruta florestal aumentaram 3,6 vezes em TI/UC, maior que o aumento em áreas não protegidas ambientalmente (1,6 vez), indicando aumento da pressão do desmatamento e um sinal alarmante em TI/UC.

Em termos de instituição e governança, as taxas anuais de perda de área florestal foram reduzidas substancialmente para as UCs nacionais (36%, 13,7 m ha) e TI (30%, 10,7 m ha),

mas apenas ligeiramente para as UC estaduais (5%, 2,7 m ha). Ainda, a maioria das UC estaduais no norte e oeste da Amazônia Legal tiveram aumentos pequenos nas taxas anuais de perda de área florestal em comparação com as outras regiões (QIN *et al.*, 2023). Um estudo constatou que, durante 2000–2008, as TI/UC nos estados fora do “Arco do Desmatamento” tiveram pouco impacto sobre o desmatamento dentro de seus limites, mas as TI e UC nacionais no “Arco do Desmatamento” foram mais eficazes na redução do desmatamento do que as UCs estaduais (HERRERA; PFAFF; ROBALINO, 2019). Outros estudos relatam que TI/UC reduziram o desmatamento na Amazônia Legal, tanto dentro de seus limites quanto em seus arredores adjacentes (QIN *et al.*, 2023).

Tanto o desmatamento quanto a degradação florestal tiveram graves impactos potenciais sobre a biodiversidade e o estoque de carbono na Amazônia Legal (ARAGÃO *et al.*, 2018; QIN *et al.*, 2021). A redução do desmatamento e da degradação florestal e o apoio à conservação e aos povos indígenas podem prevenir que os ecossistemas da Floresta Amazônica atinjam o ponto de inflexão para ecossistemas de savana (QIN *et al.*, 2023; SILVA JUNIOR *et al.*, 2019a).

2.4 O CARBONO NA BIOSFERA E ATMOSFERA

2.4.1. Produção Primária Bruta (GPP)

Na floresta amazônica, a remoção de C da atmosfera via captura, absorção e armazenamento de C na biosfera, é observada com aumento dos valores de produção primária bruta (GPP) (ALMEIDA *et al.*, 2018; CHAGAS *et al.*, 2019; ZHANG *et al.*, 2021b). O GPP está relacionado com a absorção de CO₂ durante a fotossíntese e desempenha um papel fundamental no equilíbrio de C entre a atmosfera e a biosfera (WANG *et al.*, 2017; YAN *et al.*, 2019). Assim, a análise de anomalias nos valores de GPP determina o impacto de mudanças na absorção e emissões de C (DA SILVA JUNIOR *et al.*, 2022) e, por isso, é necessário estimar, de forma precisa, as variações temporais e espaciais no GPP para entender as funções do ecossistema e as estimativas de C em resposta às mudanças climáticas e de uso e cobertura do solo (LIN *et al.*, 2017; WAGLE *et al.*, 2016).

De forma geral, os continentes apresentam uma tendência crescente de GPP anual nos últimos 17 anos (2000-2016), com maiores taxas para Europa (0,89% ao ano), Ásia (0,64% ao ano), América do Norte (0,61% ao ano), e África (0,21% ao ano) (ZHANG *et al.*, 2017a). A estimativa global de GPP para o período de 2000 a 2016 variou de 121,60 a 129,42 Pg C ano⁻¹ com uma taxa crescente de ~0,39 Pg C ano⁻¹, com maior GPP anual em regiões tropicais,

especialmente na Amazônia (ZHANG *et al.*, 2017a). Desse modo, as florestas tropicais e os cerrados são responsáveis pelas maiores proporções da GPP global, componente que desempenha um valor essencial na dinâmica espaço-temporal do CO₂ (CHAGAS *et al.*, 2019).

Como já relatado, as contribuições da tecnologia de sensoriamento remoto via uso de sensores MODIS proporcionam avanços que visem caracterizar a dinâmica da cobertura vegetal e do carbono na superfície terrestre, sendo possível estimar a absorção de carbono por meio da GPP (ROSSI; SANTOS, 2020; SILVA JUNIOR *et al.*, 2019b) A análise da GPP pelo sensor MODIS também representa avanço para os estudos climáticos e atmosféricos de carbono, tanto do ciclo global do carbono quanto na sua relação com as mudanças climáticas nos ecossistemas terrestres (ALMEIDA *et al.*, 2018).

Para entender as funções do ecossistema e as estimativas de C em resposta às mudanças climáticas temporais e espaciais, o GPP é estimado através de seu produto MOD17A2, por apresentar precisão e confiabilidade (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Os produtos MOD17, baseado no conceito de eficiência do uso da luz (LUE), fornece estimativas de GPP em todo o mundo (ALMEIDA *et al.*, 2018).

O produto MOD17A2H *collection 6* é um composto cumulativo de 8 dias com uma resolução espacial de 500 m e apresenta menores erros em relação às coleções anteriores. Também fornece duas resoluções espaciais mais grosseiras a 0,05°×0,05° e 0,5°×0,5° com uma projeção de latitude de longitude sob o *datum* WGS84 (ZHANG *et al.*, 2017a). O produto é baseado no uso eficiente da radiação solar pela vegetação (ϵ) e pode ser potencialmente utilizado como entrada para modelos de dados para calcular energia terrestre, carbono, processos do ciclo da água e biogeoquímica da vegetação (ALMEIDA *et al.*, 2018).

Na análise espacial do GPP na Amazônia dos últimos anos (2001-2019), a absorção de carbono foi de 50 a 103 gC m⁻² ano⁻¹ (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Valores diários foram encontrados para períodos semelhantes, de 9,8 gC m⁻² dia⁻¹ (2000-2006) e 8,5 gC m⁻² dia⁻¹ (2002–2005), na Amazônia brasileira central, tipicamente floresta (ALMEIDA *et al.*, 2018), que corresponde ao pico mais alto da GPP anual em torno do equador (ZHANG *et al.*, 2017a), e de 9,0 gC m⁻² dia⁻¹ (2000–2002) na região sudoeste (ALMEIDA *et al.*, 2018). Também foram observados valores de GPP acima de 16 gC m⁻² dia⁻¹ em períodos chuvosos, e máximas de 12 gC m⁻² dia⁻¹ para períodos secos, com médias para o ano de 2013-2014 de 6,54 - 7,47 gC m⁻² dia⁻¹, para áreas de floresta (CHAGAS *et al.*, 2019).

Na região sudeste, uma transição entre floresta semidecídua e cerrado, foi encontrado 7,7 gC m⁻² dia⁻¹ (2003–2006). Locais de pastagem também apresentaram média de 7,0 gC m⁻² dia⁻¹ com variação de 2,8 gC m⁻² dia⁻¹ a 11,7 gC m⁻² dia⁻¹ (ALMEIDA *et al.*, 2018).

Cerrado e pastagem tiveram o GPP médio mais baixo de $4,1 \text{ gC m}^{-2} \text{ dia}^{-1}$ (2002-2003) e $3,0 \text{ m}^{-2} \text{ dia}^{-1}$ (2001–2005), respectivamente (ALMEIDA *et al.*, 2018). Já para área agrícola em sistema de plantio direto, as médias foram de $3,5 \pm 0,5 \text{ gC m}^{-2} \text{ dia}^{-1}$ (2011-2018) em regiões ao sul da Amazônia (ROSSI *et al.*, 2021).

Os menores valores de GPP foram identificados ao redor da Amazônia, principalmente nas regiões de sul a noroeste, e os maiores, na região central (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). De forma geral, o GPP médio da Amazônia durante 2001-2019 foi de $75,1 \text{ gC m}^{-2} \text{ ano}^{-1}$, com áreas ao redor da Amazônia apresentando valores menores que $40 \text{ gC m}^{-2} \text{ ano}^{-1}$. Ainda, neste período, a floresta absorveu $1,092 \text{ Tg de C}$, mas emitiu $2,908 \text{ Tg de C}$, que é 2,66 vezes maior que o C absorvido, comprometendo assim o papel da floresta em atuar como sumidouro de C (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005).

A GPP está linearmente relacionada à radiação de fotossíntese absorvida (APAR - *absorbed photosynthetically active radiation*). APAR é o produto da radiação de fotossíntese ativa incidente (PAR - *photosynthetically active radiation*) na faixa espectral visível de $0,4 - 0,7 \mu\text{m}$ (supostamente 45% da radiação solar incidente total) e a fração de PAR absorvida por cobertura vegetal (FPAR) (CHAGAS *et al.*, 2019). Com isso, na Amazônia, a estação seca, geralmente entre junho e setembro, há aumento das temperaturas e PAR e o GPP é mínimo; em áreas de pastagem e lavoura, o GPP é afetado pelo déficit hídrico e pela menor fAPAR (ALMEIDA *et al.*, 2018).

2.4.2. Concentrações Atmosféricas de CO_2 (XCO_2)

O conhecimento preciso do balanço de carbono em escalas global e regional é importante para projetar estratégias de mitigação destinadas a estabilizar as emissões atmosféricas de dióxido de carbono (CO_2) (MUSTAFA *et al.*, 2020). O dióxido de carbono atmosférico (CO_2) é um GEE que desempenha um papel significativo em vários fenômenos da atmosfera e biosfera.

Observações de CO_2 baseadas no espaço fornecem maior cobertura observacional do que a rede observacional de superfície, e aquelas baseadas em radiação infravermelha de ondas curtas (SWIR) fornecem informações sobre CO_2 ao longo de toda a coluna atmosférica, reduzindo a sensibilidade às discrepâncias no transporte vertical (DENG *et al.*, 2016).

O GOSAT calcula as concentrações atmosféricas médias de CO_2 no caminho da luz solar refletida pela superfície por meio de espectrômetros transportados (MUSTAFA *et al.*, 2021) e é o primeiro satélite do mundo dedicado a medir as concentrações de GEE do espaço,

um esforço conjunto do Ministério do Meio Ambiente do Japão, do Instituto Nacional de Estudos Ambientais e da Agência de Exploração Aeroespacial do Japão (JAXA) (MUSTAFA *et al.*, 2020).

Lançado em 23 de janeiro de 2009, o GOSAT tem os espectros de refletância solar centrados em torno de 1,6 e 2,0 μm , usados para determinar a profundidade óptica do CO_2 , e a banda A, centrada em torno de 0,76 μm , para medir a profundidade óptica do O_2 (ESA, 2022). As informações dessas três regiões espectrais são combinadas para estimar a fração molar média de CO_2 no ar seco da coluna (XCO_2) (CRISP *et al.*, 2012). O XCO_2 mostra a variabilidade espaço-temporal e ajuda a melhorar as estimativas de concentrações de CO_2 , minimizando as incertezas das fontes e sumidouros de CO_2 (MUSTAFA *et al.*, 2020).

O satélite GOSAT é síncrono com o Sol, tem um ciclo de repetição de três dias, altitude de 667 km, cruza a linha do Equador às 13:00 \pm 0,15 hora local e incorpora um espectrômetro de transformada de Fourier para medir três canais no infravermelho de ondas curtas (0,758–0,775, 1,56–1,72 e 1,92–2,08 μm) e um na região do infravermelho térmico (5,5–14,3 μm) (ESA, 2022; KUZE *et al.*, 2009). O sensor térmico e infravermelho próximo para *Carbon Observation-Fourier Transform Spectrometer* (TANSO-FTS) e para *Carbon Observation-Cloud and Aerosol Imager* (TANSO-CAI) são os dois instrumentos incorporados no satélite GOSAT. O TANSO-FTS é responsável por medir em bandas de SWIR (0,76, 1,6 e 2,0 μm), que recupera as concentrações da XCO_2 , e a banda TIR (5,5–14,3 μm), que recupera os perfis verticais das concentrações de CO_2 , ambas com resolução espectral de 0,2-1 cm. O TANSO-CAI recupera as informações de nuvem e aerossol (DENG *et al.*, 2016).

No GOSAT, o sensor TANSO-FTS SWIR nível 2 fornece os valores de XCO_2 , em ppm, e a abundância da coluna de uma espécie de gás é definida como o número da molécula de gás, no caso o CO_2 , em uma coluna unitária vertical que se estende desde a superfície do solo até o topo da atmosfera. Um estudo de validação mostrou que o sensor TANSO-FTS, de observação de GEE, observa as concentrações médias de CO_2 da coluna com precisão (erro aleatório) de 0,5% (2 ppm) em comparação com os dados adquiridos de observações terrestres (ESA, 2022). Versões atualizadas minimizam efeitos de anomalias do sistema no período 2014-2015 e reduzem a tendência espectral, atribuídos à incerteza das variações orbitais e sazonais no nível médio de corrente contínua do TANSO-FTS sem entrada de fótons (KATAOKA *et al.*, 2019).

Emissões e absorções de CO_2 podem ser inferidas usando espectrômetros de alta resolução, como o GOSAT. A fluorescência da clorofila do espaço pode ser medida e usada para quantificar a atividade e a eficiência fotossintética globalmente, medições que são

importantes para reduzir as incertezas no ciclo global do carbono e saber onde, quando e como o CO₂ é trocado entre a terra e a atmosfera (ESA, 2022).

A concentração atmosférica de CO₂ aumentou mais de 30 ppm nos últimos 17 anos. Em 2018, o CO₂ médio foi de aproximadamente 407 ppm, para o qual emissões de CO₂ liberado de LULC foi estimado em 1 Pg C ano⁻¹ (LINDSEY, 2020; ROSSI *et al.*, 2022). Quando medido o fluxo de CO₂ global, foram identificados sumidouros maiores/fontes menores nas regiões equatoriais da América do Sul; além disso, os dados sugeriram sumidouros menores em 2010 e 2012 do que em 2011, com máximas entre -4,07 Pg C e -3,96 Pg C (DENG *et al.*, 2016).

2.4.3. Fluxo de Dióxido de Carbono (CO₂Flux)

Ações antrópicas têm causado aumento na emissão de GEE em escala global, especialmente o CO₂, acelerando assim as implicações das mudanças climáticas (ALVES *et al.*, 2017; SCHIELEIN; BÖRNER, 2018; STAAL *et al.*, 2020; ZEMP *et al.*, 2017). Uma alternativa, apontada como solução, é a manutenção ou recuperação de florestas como reservatórios naturais de carbono, pois ocupam grandes extensões de áreas no mundo (~30 – 40%) e são responsáveis pelo sequestro de 359 M Pg de C atmosférico. Nesse contexto, as florestas tropicais se destacam por representarem 25% das áreas florestadas na Terra e têm um alto potencial de fixação de carbono (15 – 25%) (ESA, 2022; MUSTAFA *et al.*, 2020).

O fluxo de carbono florestal na América tropical, entre 2000 e 2007, representou um sumidouro de 0,42 Pg C ano⁻¹, menor que os 0,65 Pg C ano⁻¹ de uma década atrás (1990 a 1999), enquanto o fluxo de carbono da rebrota tropical absorveu 0,86 e 0,81 Pg C ano⁻¹ para os mesmos períodos, respectivamente (HUI *et al.*, 2015).

Quantificar a perda de carbono atrelado à degradação e ao desmatamento é uma tarefa difícil, pois há incertezas consideráveis associadas com estimativas de áreas de floresta degradada e com cada tipo de perturbação que afeta os fluxos de carbono (SILVA JUNIOR *et al.*, 2021). Os desafios no monitoramento das emissões de carbono, no entanto, podem ser reduzidos combinando medições de campo (BARLOW *et al.*, 2016; SILVA *et al.*, 2020b) com uma gama cada vez maior de conjuntos de dados e métodos de sensoriamento remoto (BULLOCK *et al.*, 2020; INPE, 2021; OLIVEIRA *et al.*, 2020; SILVA *et al.*, 2020a) que melhoraram a capacidade de realizar o monitoramento em larga escala de processos de degradação em um todo, além de reduzir custos e tempo (GHOSH; SHARMA; JOSHI, 2014).

O fluxo de CO₂, ou índice CO₂Flux (RAHMAN *et al.*, 2001), é usado para estimar a eficiência do processo de absorção de carbono relacionado à vegetação e pode ser realizado por

meio de sensoriamento remoto (BOAS DOS SANTOS, 2017; ROSSI *et al.*, 2021). Os valores negativos frequentemente indicam remoção do CO₂ e valores positivos representam a emissão (ROSSI *et al.*, 2021).

Para o cálculo do índice CO₂Flux, frequentemente são utilizados dois índices de vegetação, o Índice de Vegetação Fotossintético (PRI), que estima os pigmentos de carotenoides das folhas, indicando a taxa de armazenamento de CO₂ nas folhas (GAMON; SERRANO; SURFUS, 1997) e o NDVI, que demonstra o vigor da vegetação fotossinteticamente ativa, na qual pode ser capaz de capturar absorções de carbono (BARNES *et al.*, 2017; RAHMAN *et al.*, 2001; ROSSI *et al.*, 2021).

O PRI utiliza uma formulação análoga ao NDVI, com uma medição de reflectância em 0,531 μm que é sensível a mudanças nos pigmentos carotenóides (especialmente pigmentos de xantofila) nas folhagens da vegetação, e essa medição é comparada à uma medição de reflectância de referência em 0,570 μm. Os pigmentos carotenóides são um indicativo da eficiência do uso da luz na fotossíntese e da taxa de absorção de CO₂ pela folhagem por unidade de energia (solar) absorvida. O PRI é aplicado em análises de estresse e produtividade da vegetação antes da senescência. Seus valores variam de -1 a 1, sendo que a vegetação verde usualmente apresenta valores na faixa de -0,2 a 0,2.

Para o cálculo do índice CO₂Flux, o índice PRI é escalonado para valores positivos. Além disso, para adequação dos resultados de CO₂Flux com a Amazonia Legal, correlações entre valores adquiridos por sensoriamento remoto e valores medidos por torres micrometeorológicas, determinados pelo método de covariância de vórtices turbulentos, foram estudadas e são frequentemente utilizadas com uma melhor correlação (BOAS DOS SANTOS, 2017; DELLA-SILVA *et al.*, 2022; ROSSI *et al.*, 2021).

Em áreas de cultivo, valores médios de CO₂Flux foram de -5 ± -5 (2000-2003) e de 3 ± 6 μmol m⁻² s⁻¹ (2004-2018), com absorção de CO₂ maior em sistema plantio direto em relação ao sistema convencional (ROSSI *et al.*, 2021). Estudo em 2017 no sul da Amazônia apresentou valores próximos a $-7,18 \pm -2,92$ para florestas e $6,46 \pm 2,23$ para solos descobertos, com valores intermediários para pastagem (DELLA-SILVA *et al.*, 2022).

Com relação à variabilidade espacial, áreas de floresta que foram convertidas para outros usos do solo resultaram em valores mais altos de concentrações de CO₂, que caracterizam com fontes de GEE, enquanto grandes áreas de floresta contínua tendem a ter valores mais baixos XCO₂ e contribuem positivamente para o balanço de carbono como sumidouros, mitigando os impactos das mudanças climáticas (ROSSI *et al.*, 2022).

2.5 PRECIPITAÇÕES NA AMAZÔNIA LEGAL BRASILEIRA

As emissões de carbono da Amazônia são cada vez mais dominadas por incêndios florestais durante secas extremas. Para os anos de 2005, 2007, 2010 e 2015, contribuições de incêndios florestais foram superiores a 50% dos valores de emissão do desmatamento, muito provavelmente por terem sido anos de seca (ARAGÃO et al., 2018). Além disso, no ano de 2015, por exemplo, uma diminuição severa das chuvas ocorreu no Arco do Desmatamento (QIN et al., 2023). Essa diminuição foi principalmente para os estados de Mato Grosso, Rondônia e Acre, regiões sul e sudoeste da Amazônia Legal, que tiveram chuvas abaixo de 1.360 mm e, em casos extremos, inferiores a 520 mm (DA SILVA JUNIOR et al., 2022; ZHAO et al., 2005).

Pesquisas relacionadas a secas, incêndios, desmatamento e emissões de C foram relatadas na Amazônia associadas ao fenômeno *El Niño Southern Oscillation* (ENSO). O ENSO é caracterizado por anomalias positivas (*El Niño*) ou negativas (*La Niña*) da temperatura da superfície do mar (SST) e é o principal fator de extremos climáticos interanuais nas regiões tropicais, representando eventos com grandes impactos ambientais (FERREIRA BARBOSA et al., 2021). Durante o fenômeno ENSO, maiores registros de focos de incêndios foram entre agosto e dezembro, com destaque para novembro e dezembro de 2015, apesar de serem meses chuvosos. Mato Grosso teve o maior número de focos de incêndio na maioria dos anos, seguido do Pará, que se tornou o estado com mais focos nos anos de *El Niño* e em 2009/2010, representando 38% dos focos de incêndio no período (FERREIRA BARBOSA et al., 2021).

A Amazônia se encontra em uma região de anomalias da SST nas regiões do Pacífico e Atlântico para *El Niño* 1+2 (90°W–80°W, 0°–10°S), *El Niño* 3.4 (N34; 120°W–170°W, 5°S–5°N), Atlântico Norte Tropical (15°W–57,5°W; 5,5°N–23,5°N) e Atlântico Sul Tropical (10°E–30°W, 0°–20°S). Este prolongado evento de *El Niño* 3.4 em 2015/16, combinado com a tendência de aquecimento regional, foi associado a um aquecimento sem precedentes e a uma maior extensão de seca extrema na Amazônia em comparação com os fortes eventos de *El Niño* anteriores em 1982/83 e 1997/98 (JIMÉNEZ-MUÑOZ et al., 2016).

Neste sentido, já é de se esperar que, para os anos mais secos na Amazônia, menores valores são encontrados para GPP e maiores para GEE, conseqüentemente, como foi o caso de 2005, 2010 e 2015, assim como também, períodos mais secos (junho a agosto) há queda na GPP em relação a períodos chuvosos (dezembro a março) para o leste da Amazônia Legal (DA SILVA JUNIOR et al., 2022; ZHAO et al., 2005).

O conjunto de dados CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station*) foi desenvolvido pela *United States Geological Survey* e pelo *Climate Hazards Group*

da Universidade da Califórnia, Santa Bárbara (FUNK *et al.*, 2014). Este conjunto de dados combina climatologia de precipitação pentadal (períodos de 5 dias), observações de satélite infravermelho termal (TIR) geostacionário quase global do Centro de Previsão Climática (CPC) do *National Climatic Data Center* (KNAPP *et al.*, 2011), campos de precipitação do modelo atmosférico do NOAA *Climate Forecast System* (CFSv2) (SHAH; BHARADIYA; MANEKAR, 2015), e observações de precipitação *in situ* (DE OLIVEIRA-JÚNIOR *et al.*, 2021; TOTÉ *et al.*, 2015).

É bastante comum o uso de CHIRPS em pesquisas em que se há falta de dados temporais de estações *in situ*, como é o caso da Amazônia, e por causa de sua disponibilidade de 1981 até o presente em uma resolução espacial de $0,05^\circ$ ($\sim 5,3$ km) em resoluções temporais pentadais, mensais e diárias (DA SILVA JUNIOR *et al.*, 2022; ROSSI *et al.*, 2022). Trabalhando com dados de CHIRPS, verificou-se que a variabilidade temporal do CO_2Flux está correlacionada positivamente com a precipitação, enquanto XCO_2 está negativamente correlacionada com a precipitação, e que as maiores e menores concentrações médias de CO_2 ocorreram nos meses seco e chuvoso, respectivamente (ROSSI *et al.*, 2022).

A Amazônia recebeu precipitação média no início da série temporal (2001) até meados de 2008 (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005) e, a partir de 2009, houve alta variabilidade dos regimes úmidos e secos, principalmente em 2010 e 2015, coincidindo com anos de influência do *El Niño* (ARAGÃO *et al.*, 2018). Nos anos de 2005, 2010 e 2015, houve redução mais acentuada das chuvas, principalmente em 2015, com precipitação inferior a 1640 mm (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Os valores para esses anos de seca foram considerados os mais severos deste século e significativos para as emissões de C na BLA (ARAGÃO *et al.*, 2018; MARENGO; ESPINOZA, 2016; TOWNER *et al.*, 2020).

Considerando o período de 2001-2019, a precipitação na Amazônia mostrou que as regiões do sul e leste, no Arco do Desmatamento (HERRERA; PFAFF; ROBALINO, 2019; PERES, 2023; QIN *et al.*, 2023), apresentaram chuvas abaixo de 1000 mm ano^{-1} , inferior à média climatológica registrada na Amazônia central (2200 mm), como ocorreu na região noroeste (DA SILVA JUNIOR *et al.*, 2022; QIN *et al.*, 2023; ZHAO *et al.*, 2005).

Além disso, uso de dados SR, com o é o caso do produto MOD17A2H *collection 6*, foram relatadas tendências de superestimação do GPP em locais de baixa produtividade, como os meses de junho a agosto, um período seco, e subestimação em locais de alta produtividade, para os meses de dezembro a março, período chuvoso (ALMEIDA *et al.*, 2018), e, por isso, é preciso cautela para interpretar seus valores. Também é relatado que as coleções MOD17 GPP

5.0, 5.5 e 6.0 são melhoradas quando são adicionados dados meteorológicos específicos do local e classificação corrigida de uso e cobertura do solo.

Com isso, na Amazônia, a estação seca, geralmente entre junho e setembro, há aumento das temperaturas e o GPP é mínimo (ALMEIDA *et al.*, 2018). No Cerrado, mais especificamente no Arco do Desmatamento (PERES, 2023; SILVA JUNIOR *et al.*, 2019a), as variações sazonais são características do clima subtropical com uma estação seca de inverno. Assim, na estação chuvosa, a temperatura e a PAR são relativamente baixas, com GPP mais alto; com o aumento do déficit hídrico na estação seca, o GPP diminui (DA ROCHA *et al.*, 2009). Em áreas agrícolas, em época de seca, o GPP é afetado (ALMEIDA *et al.*, 2018). Isso mostra que dados meteorológicos estão fortemente correlacionados e são imprescindíveis para maior precisão dos dados (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005).

Considerando anos de *El Niño*, a variação foi de 0 a 1.032 mm na Amazônia Legal. O valor máximo em setembro de 2015 foi de 209,33 mm e uma média de 172,51 mm. Em setembro de 2009, a média foi de 173,61 mm e a variação de 0 a 304,51 mm, dependendo da localidade. Entre 2009/2010, o mês que mais choveu foi junho, com 43,50 mm, seguido de dezembro, com 24,49 mm; os meses que choveram abaixo da média foram março (-54,30 mm), fevereiro (-44,39 mm) e novembro. O ano de 2015 foi o que apresentou as maiores anomalias negativas, destacando-se dezembro (-81,64 mm), novembro (-57,99 mm) e setembro (-44,90 mm) (FERREIRA BARBOSA *et al.*, 2021).

Os anos de *La Niña* tiveram o maior número de focos de incêndio em 2010/2011 (*La Niña* forte) e em 2007/2008 (*La Niña* moderada), principalmente no mês de setembro, com áreas de cerrado e florestas ombrófilas abertas as mais afetadas. Neste período, além do Pará (2007/2008), o Tocantins (2010/2011) foi um dos estados mais afetados com focos de incêndios (FERREIRA BARBOSA *et al.*, 2021).

Entre 2007/2008, foram encontradas as maiores anomalias positivas, com chuvas abaixo de 32 mm para os meses chuvosos (janeiro a abril). A maior anomalia negativa foi registrada em setembro (período seco), que choveu -14,54 mm em relação à climatologia. Já os anos de 2003/2004 e 2013 foram períodos de neutralidade, isto é, os valores pluviométricos variaram de 0 em agosto de 2013 a 1.084 mm em abril de 2003 (FERREIRA BARBOSA *et al.*, 2021).

3. MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

A Amazônia Legal brasileira (BLA) (BRASIL, 2007) compreende os seguintes estados: Acre, Amapá, Amazonas, Mato Grosso, Rondônia, Roraima, Tocantins, Pará, e parte do estado do Maranhão, localizado a oeste do meridiano 44° (Figura 1). Possui uma superfície de 5,02 M km², correspondente a 58,9% do território brasileiro (IBGE, 2021). A BLA contém três dos biomas do Brasil, a Amazônia, o Cerrado e o Pantanal (COUTINHO, 2016; FLACH *et al.*, 2021; IBGE, 2021). Enquanto a Amazônia é coberta principalmente por florestas tropicais úmidas, o Cerrado é um bioma coberto por uma variedade de vegetação do tipo savana, e o Pantanal é coberto por um mosaico de campos, campos alagados, cerrado arborizado e matas ciliares (AMIGO, 2020; ARAGÃO *et al.*, 2014; COUTINHO, 2016).

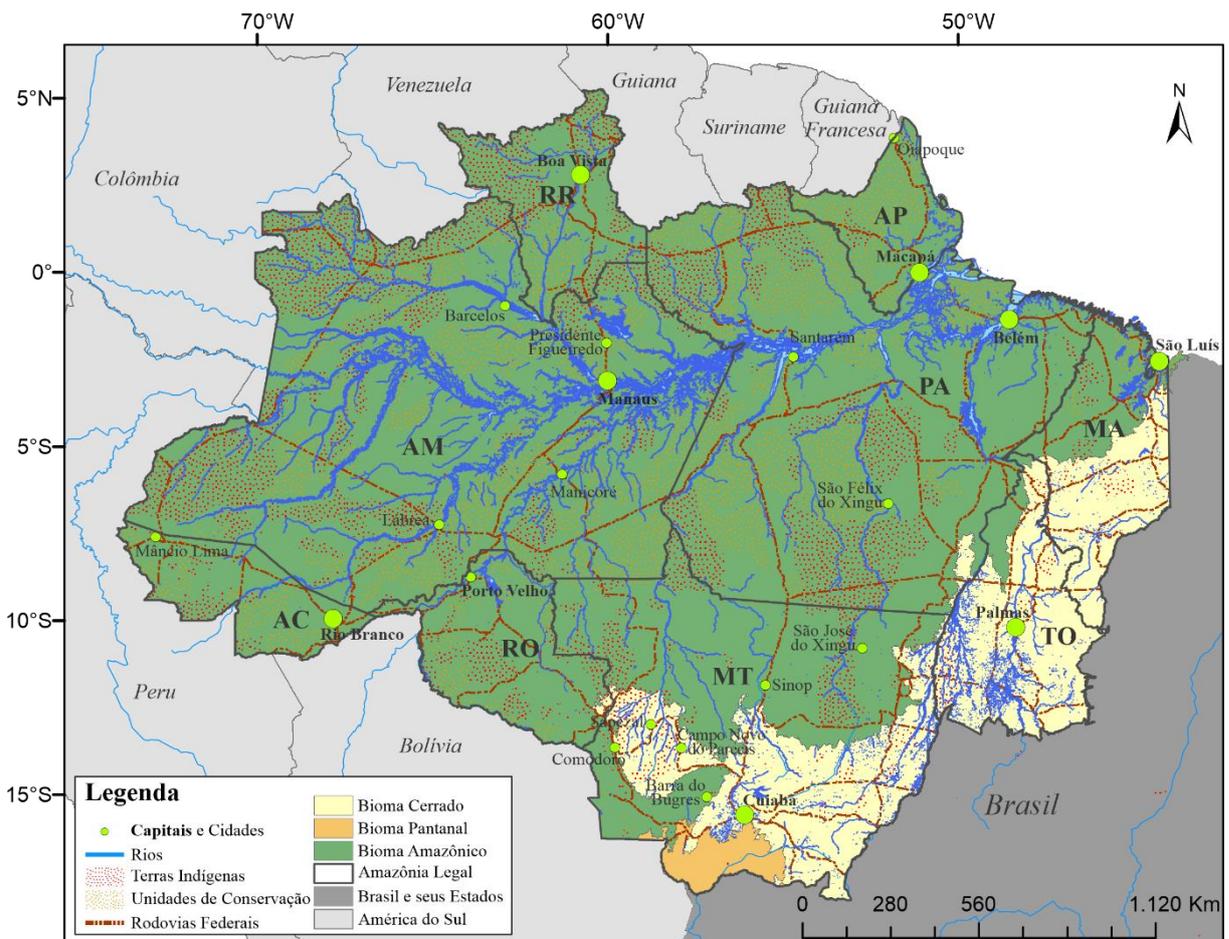


Figura 1 - Amazônia Legal brasileira e seus biomas, terras indígenas, unidades de conservação, rodovias federais e rios (COUTINHO, 2016; IBGE, 2020, 2021). Estados do Acre (AC), Amapá (AP), Amazonas (AM), Mato Grosso (MT), Maranhão (MA), Rondônia (RO), Roraima (RR), Tocantins (TO) e Pará (PA).

O clima predominante na BLA é o do tipo “A”, ou tropical, em que a temperatura média mensal nunca é inferior a 18 °C (ALVARES *et al.*, 2013). São destacadas três tipificações climáticas: o tipo “Af” (quente e chuvoso durante todo o ano), localizados no noroeste da BLA até a região da foz do Amazonas (redor da ilha de Marajó-PA), o tipo “Am” (clima tropical úmido ou sub-úmido), com a transição entre os climas tropicais úmidos e os com longa estação seca (Amazônia meridional), e o tipo “Aw” (clima tropical, com inverno seco), entre o sul e leste da Amazônia Legal, predominante nos Estados de Mato Grosso, Rondônia, Tocantins e Maranhão (DUBREUIL *et al.*, 2018).

A maior parte das TIs concentra-se na Amazônia Legal. Foram selecionadas 424 áreas, 1.153.444,45 km², que correspondeu a 98,25% da extensão de todas as TIs do país. Também, 307 UCs foram selecionadas, totalizando 1.174.258 km² (Figura 1). As TIs e UCs que foram mais prejudicadas pela mudança no uso e cobertura do solo foram analisadas utilizando o software pelo ArcGIS versão 10.8, obtendo-se o nome da TI ou UC, o município e a etnia (para TI), e destacadas descritivamente ao longo do texto.

3.2 DADOS

Dados dos MODIS foram utilizados para uso e cobertura do solo, produção primária bruta (GPP) e fluxo de dióxido de carbono (CO₂Flux) por apresentarem a mesma resolução espacial, de 500 m, serem mais adequados para trabalhar em áreas remotas e extensas, como a BLA, e por trazerem dados mais rápidos e com baixo custo (ALSHARI; GAWALI, 2021; GHOSH; SHARMA; JOSHI, 2014). Dados de GOSAT foram selecionados em detrimento de outros satélites que apresentam concentrações de XCO₂, por sua resolução temporal, a partir de 2009 (CRISP *et al.*, 2012; ESA, 2022; MUSTAFA *et al.*, 2021), bem como CHIRPS, e por este ser o mais indicado para a área de estudo (DA SILVA JUNIOR *et al.*, 2022; FUNK *et al.*, 2014).

3.2.1 Dados de uso e cobertura do solo

Para quantificar as variações temporais e espaciais no uso e cobertura do solo na BLA foi usado o produto MCD12Q1 versão 06 do sensor MODIS (*Moderate-Resolution Imaging Spectroradiometer*) a bordo do satélite Terra e Aqua (FRIEDL; SULLA-MENASHE, 2019). O produto MCD12Q1 foi escolhido por apresentar alta precisão ao longo do tempo e por sua disponibilização gratuita (AHMAD *et al.*, 2022; BROWN *et al.*, 2022; CAÚLA *et al.*, 2017; HE *et al.*, 2022; SILVA *et al.*, 2023).

O algoritmo que processa o produto MCD12Q1 (V006 Global 500 m *Land Cover Type Product*) é baseado em uma classificação de árvore de decisão supervisionada de dados de refletância e fornece tipos globais de cobertura do solo em intervalos anuais em 500 m de resolução espacial (SULLA-MENASHE; FRIEDL, 2018). Este contém cinco tipos de classificações que descrevem as propriedades de cobertura da superfície, em sequência, são os esquemas de classificação derivados do *International Geosphere - Biosphere Programme* (IGBP), *University of Maryland* (UMD), *Leaf Area Index* (LAI), *BIOME-Biogeochemical Cycles* (BGC) e *Plant Functional Types* (PFT).

O primeiro esquema de cobertura de superfície identifica 17 classes definidas pelo Programa Internacional de Geosfera da Biosfera (IGBP), que inclui 11 classes de vegetação natural, 3 classes de parcelas urbanizadas e 3 classes de solo não vegetado (Tabela 1). A classificação do Tipo 1 foi utilizada entre os anos 2009 e 2019, por ser a classificação mais completa considerando os propósitos deste estudo (CAÚLA *et al.*, 2017; FRIEDL; SULLA-MENASHE, 2019; SILVA *et al.*, 2023). Foi classificada toda a Amazonia Legal e as fitofisionomias do bioma brasileiro foram utilizadas para a tradução correspondente as classes de uso e cobertura do solo brasileiro (RIBEIRO; WALTER, 2008).

Tabela 1 - Classificação Tipo 1 do produto MCD12Q1

Classe	Cor	Sigla	Descrição
1	05450a	ENF	Florestas perenes de folha estreita: dominadas por árvores coníferas perenes (copa > 2 m). Cobertura de árvores > 60%.
2	086a10	EBF	Florestas perenes de folha larga: dominadas por árvores perenes de folha larga e palmeiras (copa > 2 m). Cobertura de árvores > 60%.
3	54a708	DNF	Florestas decíduas de folha estreita: dominadas por árvores decíduas de folha agulha (larício) (copa > 2 m). Cobertura de árvores > 60%.
4	78d203	DBF	Florestas decíduas de folha larga: dominadas por árvores decíduas de folha larga (copa > 2 m). Cobertura de árvores > 60%.
5	009900	MF	Florestas mistas: dominadas por tipo de árvore nem decídua nem perene (40-60% de cada) (copa > 2 m). Cobertura de árvores > 60%.
6	c6b044	CS	Cerradão: dominados por plantas perenes lenhosas (1-2 m de altura) >60% de cobertura.
7	dcd159	OS	Cerrado denso: dominados por plantas perenes lenhosas (altura de 1-2m) com cobertura de 10-60%.
8	dade48	WSV	Cerrado típico: cobertura arbórea de 30-60% (copa > 2 m).
9	fbff13	SV	Cerrado ralo: cobertura arbórea de 10-30% (copa > 2 m).
10	b6ff05	GL	Campos ou Pastagem: dominadas por plantas anuais herbáceas (<2m).
11	27ff87	PW	Pântano: terras permanentemente inundadas com 30-60% de cobertura de água e > 10% de cobertura vegetal.
12	c24f44	CL	Cultivo agrícola: pelo menos 60% da área é área cultivada.

13	a5a5a5	UBL	Área urbana/terrenos urbanos e construídos: pelo menos 30% da superfície impermeável incluindo materiais de construção, asfalto e veículos.
14	ff6d4c	NVM	Mosaicos de cultivo/vegetação natural: mosaicos de cultivo em pequena escala 40-60% com árvore natural, arbusto ou vegetação herbácea.
15	69fff8	PSI	Neve e gelo permanentes: pelo menos 60% da área é coberta por neve e gelo por pelo menos 10 meses do ano.
16	f9ffa4	BN	Deserto ou Solo descoberto: pelo menos 60% da área é estéril sem vegetação (areia, rocha, solo) com menos de 10% de vegetação.
17	1c0dff	WB	Corpos d'água: pelo menos 60% da área é coberta por corpos d'água permanentes.

Fonte: (FRIEDL; SULLA-MENASHE, 2019; RIBEIRO; WALTER, 2008).

Os parâmetros de tempo e espaço para cada uso e cobertura do solo foram calculados usando a linguagem JavaScript como entrada na plataforma *Google Earth Engine* (GORELICK *et al.*, 2017). Para a análise das estimativas de carbono, foram selecionados aleatoriamente 10 pontos, representativos de cada classe de uso e cobertura do solo no BLA e para cada ano, de modo a garantir que um determinado ponto fosse sempre considerado a mesma classe por todos os anos estudados. Isso foi necessário para verificar se as emissões induzidas por mudanças no uso e cobertura do solo no BLA ao redor desses pontos selecionados estavam impactando a classe. Esses pontos foram coletados pela plataforma *Google Earth Engine*, por meio da aba “Inspetor”. Os pontos foram aproximados de 1 a 2 km por pixel (HE *et al.*, 2022).

3.2.2 Dados de Produção Primária Bruta (GPP)

Para analisar o GPP em todas as classes de uso e cobertura do solo, foi obtido o produto MYD17A2H, que é uma composição cumulativa dos valores GPP com base na eficiência de uso da radiação solar pela vegetação (ϵ) (MONTEITH, 1972; RUNNING; ZHAO, 2019). O algoritmo desse produto do MODIS converte (através de uma tabela de pesquisa de eficiência de conversão) a radiação fotossinteticamente ativa absorvida (relacionada à quantidade total de área foliar) em absorção de carbono (ALMEIDA *et al.*, 2018; FELTON; GOLDSMITH, 2023). Nesta lógica, a GPP é linearmente relacionada à radiação fotossinteticamente ativa absorvida, que pode ser calculada como o produto da radiação fotossinteticamente ativa incidente (PAR), na faixa espectral visível (0,4 - 0,7 μm), assumida como 45% da radiação solar incidente total, e a fração de radiação fotossinteticamente ativa absorvida pela cobertura vegetal (FPAR) (DELGADO *et al.*, 2018; HEINSCH *et al.*, 2003). Assim, o GPP é calculado conforme a Equação 1:

$$GPP = \varepsilon \times PAR \times FPAR \quad (1)$$

Um dos maiores desafios no uso de tais modelos é obter a eficiência do uso da luz " ε " em uma grande área, devido à sua dependência de fatores ambientais e da própria vegetação. Uma das soluções consiste em relacionar " ε " de acordo com seu valor máximo (ε_{max}) mais as contribuições ambientais sintetizadas pela temperatura mínima do ar ($T_{minscalar}$) e o estado da água na vegetação (VPD_{scalar} - déficit de pressão do vapor d'água) (FIELD; RANDERSON; MALMSTRÖM, 1995), de acordo com a Equação 2:

$$\varepsilon = \varepsilon_{max} \times T_{minscalar} \times VPD_{scalar} \quad (2)$$

O produto GPP cumulativo de 8 dias MYD17A2H MODIS (2009–2019; 11 anos no total) foi adquirido usando a linguagem JavaScript como entrada na plataforma *Google Earth Engine* (GORELICK *et al.*, 2017). Os valores GPP foram convertidos do valor cumulativo a cada 8 dias para valores médios anuais ($gC\ m^{-2}\ ano^{-1}$) (HEINSCH *et al.*, 2003).

3.2.3 Fluxo de dióxido de carbono (CO₂Flux)

Para estimar os fluxos anuais de dióxido de carbono das florestas ($\mu mol\ m^{-2}\ s^{-1}$) foi empregado o fluxo de dióxido de carbono (CO₂Flux). Este é um modelo empírico baseado em sensoriamento remoto, que relaciona dois índices de vegetação (RAHMAN *et al.*, 2001), o Índice de Vegetação por Diferença Normalizada (NDVI) (Eq. 3), e o Índice de Reflectância Fotoquímica escalonado (sPRI) (Eq. 4). Valores negativos representam um sumidouro de CO₂, enquanto valores positivos representam uma fonte de CO₂ (BOAS DOS SANTOS, 2017; DELLA-SILVA *et al.*, 2022; RAJU *et al.*, 2023; ROSSI *et al.*, 2022). Enquanto o NDVI revela o vigor da vegetação fotossinteticamente ativa, na qual pode ser capaz de absorver carbono (BARNES *et al.*, 2017; DELLA-SILVA *et al.*, 2022; RAHMAN *et al.*, 2001; ROSSI *et al.*, 2021, 2022), o sPRI estima os pigmentos carotenóides das folhas, indicando a taxa de armazenamento de dióxido de carbono nas folhas (SILVA *et al.*, 2023). Para o cálculo de NDVI, foram utilizadas as bandas espectrais 1 (620 – 670 nm) e 2 (841 – 876 nm), para o vermelho (R) e o infravermelho próximo (NIR), com base no produto MOD09A1 (Eq. 3) (DELLA-SILVA *et al.*, 2022). As bandas utilizadas do produto MOD09A1 possuem resolução espacial de 500 m e resolução temporal de 1 a 2 dias (VERMOTE, 2018). Para estimar o sPRI,

foram utilizadas as bandas espectrais 3 (459 – 479 nm), para o azul (B), e 4 (545 – 565 nm), para o verde (G), do produto MOD09A1 (Eq. 4).

$$NDVI = \frac{NIR - R}{NIR + R} \quad (3)$$

$$sPRI = \frac{\left(\frac{B - G}{B + G} + 1\right)}{2} \quad (4)$$

Os valores do CO₂Flux (μmol m⁻² s⁻¹) foram estimados anualmente tomando a mediana anual da série temporal (Eq. 5). Os fatores utilizados na equação foram calibrados com base no método de Covariância de Vórtices Turbulentos em torres micrometeorológicas (BOAS DOS SANTOS, 2017; DELLA-SILVA *et al.*, 2022; ROSSI *et al.*, 2022).

$$CO_2Flux = 13.63 - 66.207 (NDVI \times sPRI) \quad (5)$$

Os valores medianos anuais foram calculados entre 2009-2019 usando a linguagem JavaScript como entrada na plataforma *Google Earth Engine* (GORELICK *et al.*, 2017).

3.2.4 Concentração atmosférica de CO₂ (XCO₂)

Os dados de concentração atmosférica de CO₂ (XCO₂) foram adquiridos do Satélite de Observação de Gases do Efeito Estufa (GOSAT) para avaliar o comportamento espacial e temporal do XCO₂ ao longo de 11 anos (abril de 2009 a dezembro de 2019) no BLA. O GOSAT calcula a média de XCO₂ no caminho da luz solar refletida pela superfície (CRISP *et al.*, 2012; ESA, 2022; MUSTAFA *et al.*, 2021).

O XCO₂ não atendeu a todas as classes de uso e cobertura do solo porque tem uma resolução espacial de 2,5°, ou 278 km no equador, impossibilitando sua detecção pela maioria das classes (ESA, 2022), por isso foi realizada a análise de pontos quentes pelo método de Getis-Ord. Além disso, uma média dos valores anuais foi realizada no período e área estudados e as diferenças de um ano para o outro, em ppm, foram descritos no texto, por representarem incrementos de XCO₂ significativos.

3.2.5 Dados de precipitação

Para identificar os padrões de precipitação durante 2009-2019 nas diferentes classes de uso e cobertura do solo do BLA, foi utilizado o *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), com resolução espacial de 0,05° (±5,3 km) e resolução temporal

diária (DA SILVA JUNIOR *et al.*, 2022; FUNK *et al.*, 2014). Apresenta dados satisfatórios para a avaliação espaço-temporal da precipitação regional na Amazônia, principalmente porque esta região carece de dados de estações meteorológicas *in situ* (DA SILVA JUNIOR *et al.*, 2022; DE OLIVEIRA-JÚNIOR *et al.*, 2021). Os valores da somatória anual foram calculados entre 2009-2019 pela plataforma *Google Earth Engine* com programação em linguagem JavaScript (GORELICK *et al.*, 2017).

3.3 ANÁLISES

3.3.1 Mudança de uso e cobertura do solo de 2009 a 2019

Como primeiro passo para entender os fluxos de carbono na região, foram analisadas as mudanças nas classes de uso e cobertura do solo entre 2009 e 2019. Foi calculada a área ocupada por cada classe em cada ano e determinadas as classes com maiores áreas de mudança.

3.3.2 Agrupamento espacial de carbono atmosférico

A avaliação espacial e temporal de XCO₂ foi realizada com a análise de pontos quentes (*hot spots*), pelo método de Getis-Ord (GETIS; ORD, 1992), conforme a Equação 6, para facilitar a comparação com as classes de uso e cobertura do solo, devido a sua resolução espacial de 278 km no equador:

$$G_i = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\left[\frac{n \sum_{j=1}^n w_{i,j}^2 - (\sum_{i=0}^n w_{i,j})^2}{n-1} \right]}} \quad (6)$$

Onde: G_i significa a dependência espacial do incidente i em todos os eventos n; x_j é a magnitude da variável X no local do incidente j nas observações (n) (j pode ser igual a i); e, w_{ij} é o valor do peso entre o evento i e j representando a inter-relação espacial.

A estatística G_i visa identificar agrupamentos espaciais significativos de valores altos (*hotspot*) ou baixos (*coldspot*) nas observações, desenvolvidas para conjuntos de dados nos quais não há autocorrelação espacial global (GETIS; ORD, 1992). Análise de pontos quentes foi realizada pelo ArcGIS versão 10.8, e os pontos foram transformados para *raster* para proporcionar uma melhor visualização.

3.3.3 Teste de normalidade

Os conjuntos de dados GPP, CO₂Flux e Chuva compreendendo 11 anos (2009 a 2019) e 10 classes (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL e WB) foram submetidos ao teste de normalidade de Shapiro-Wilk, com o pacote “RVAideMemoire” no R (R CORE TEAM, 2018). Este pacote permite analisar a normalidade dos valores dentro de um grupo e verificar se os dados estão distribuídos parametricamente com maior assertividade, isso porque este teste contém diversas funções úteis em bioestatística, principalmente procedimentos de testes univariados e multivariados, com ênfase especial em testes de permutação (HERVÉ, 2016).

Também foi realizado um teste de normalidade de Shapiro-Wilk sem considerar grupos; no entanto, não considerar grupos para amostras maiores de dados pode introduzir erros e a função `RVAideMemoire::byf.shapiro()` pode ajudar a verificar isso. Essa função é uma escolha excelente para examinar questões sobre normalidade por quebras de variáveis de objeto do tipo fator (MACFARLAND; YATES, 2021). Para permitir uma visualização comparativa entre as três variáveis (GPP, CO₂Flux e Chuva) e complementar o teste de normalidade, foi gerado o histograma, pois este apresenta a distribuição e frequência em relação ao centro.

3.3.4 Variabilidade do fluxo de carbono de classes de uso e cobertura do solo

Para comparar como os fluxos de C variaram entre as diferentes classes de uso e cobertura do solo, foi empregado o teste não paramétrico de Kruskal-Wallis (KW), correspondente a anova de uma via. O teste KW classifica os valores e os grupo com distribuições diferentes podem ser comparados com base em suas medianas (DIRIKOLU *et al.*, 2023; KROEGER *et al.*, 2022). O teste KW foi utilizado para identificar quais parâmetros (classes de uso e cobertura do solo ou anos) apresentaram diferenças significativas entre as variáveis (GPP, CO₂Flux e Chuva) em toda a BLA (DÍAZ ARANGO, 2023; DIRIKOLU *et al.*, 2023). A magnitude das alterações foi calculada pela diferença percentual entre as medianas (DIRIKOLU *et al.*, 2023; KROEGER *et al.*, 2022).

Para identificar em quais grupos ocorreram estas diferenças observadas, foi realizado um teste *post-hoc* de Dunn (DÍAZ ARANGO, 2023; DIRIKOLU *et al.*, 2023), com ajuste do valor de *p* pelo método de “bonferroni”, um ajuste para múltiplas comparações. O método de “bonferroni” é mais conservador e garante a diferença entre estes grupos. Para as comparações entre grupos com dados não paramétricos, utilizou-se o pacote “rstatix” no R (R CORE TEAM, 2018). As medianas e as amplitudes interquartis das variáveis GPP, CO₂Flux e Chuva e das 10

classes de uso e cobertura do solo (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL e WB) foram obtidas pelo produto “get_summary_stats”, do pacote “rstatix”. *Boxplots* e *scatterplots* mostrando a variabilidade gráfica de GPP, CO₂Flux e Chuva entre as 10 classes de uso e cobertura do solo também foram produzidos. Essas análises foram realizadas no software R utilizando os pacotes ggplot2 e GGEbiplotGUI (R CORE TEAM, 2018).

3.3.5 Análise de Cluster

Para avaliar as afinidades entre o uso e cobertura do solo e as variáveis de emissão/absorção de carbono e precipitação, foram empregadas análises de cluster baseadas nos componentes principais e métodos de dendrograma (REGAZZI; CRUZ, 2020). A análise de cluster se baseia em aprendizado não supervisionado, na qual os dados são segmentados em grupos com base em uma análise exploratória, em caso de ausência ou dúvida de uma variável dependente. Dessa forma, o *cluster* realiza a segmentação no conjunto de dados por meio de seus atributos, organizando e facilitando a visualização ao agrupar variáveis com semelhanças. Também auxilia na detecção de anomalias ou *outliers*.

Grupos de *clusters* que minimizam a dissimilaridade, ou minimizam somas totais de quadrados dentro de grupos também são conhecidos como Soma do Desvio Quadrático (SQD) (WARD, 1963). Em cada etapa do procedimento, os grupos foram formados de tal forma que a solução resultante tem o menor SQD dentro dos grupos. Foi considerada a união de todos os possíveis pares de grupos. Os dois grupos que resultaram em um menor aumento no SQD foram agrupados para formar um único grupo que reúne todos os indivíduos (EVERITT; DUNN, 1991; TEODORO *et al.*, 2015).

Os *clusters* foram gerados usando os dados de GPP, CO₂Flux e Chuva escalados, levando em consideração cada uso e cobertura do solo entre 2009-2019. Para isso, a distância Euclidiana e o método hierárquico de Ward foram usados (EVERITT; DUNN, 1991; TEODORO *et al.*, 2015; WARD, 1963) (Eq. 7):

$$d_e = \left[\sum_{j=1}^n (P_{p.j} - P_{k.j})^2 \right]^{\frac{1}{2}} \quad (7)$$

Em que: d_e é a distância euclidiana; P_p e P_k são as variáveis j dos sujeitos p e k .

A análise de componentes principais (PCA) também foi realizada para examinar se as variáveis GPP, CO₂Flux e Chuva, derivadas de dados de sensoriamento remoto, poderiam ajudar a caracterizar diferentes usos e coberturas do solo na BLA (CAMARRETTA *et al.*, 2021;

REGAZZI; CRUZ, 2020). A PCA é uma análise estatística multivariada que transforma um conjunto de dados original em outro conjunto de dados com as mesmas dimensões, reduzindo a massa de dados com perda mínima de informações. As componentes principais são derivadas da combinação linear das variáveis originais, que são independentes umas das outras (REGAZZI; CRUZ, 2020).

3.3.6 Análise de tendência

Para identificar os anos com tendência ao longo da série temporal (2009-2019) para cada variável, foi empregado o teste de Mann-Kendall (MK) (KENDALL, 1975; MANN, 1945), que se assemelha à análise de regressão e indica se os valores da série temporal tendem a aumentar ou diminuir ao longo do tempo, ou se o valor central na distribuição dos dados da série temporal muda. Quando comparado a outros testes paramétricos, apresenta maior robustez quanto a desvios de normalidade e não-estacionaridade dos dados da série histórica, justificando o amplo uso em estudos de tendência (AHMAD *et al.*, 2022; CAÚLA *et al.*, 2017). Também foi utilizado o teste de Pettitt, que mostra quando foi esta tendência ou confirma a estacionariedade da série histórica, utilizando-se uma versão do teste de Mann-Whitney, que verifica se duas amostras pertencem à mesma população (PETTITT, 1979). Para a aplicação dos testes de Mann-Kendall e de Pettitt, foi utilizado o pacote “trend” e “ManKendall” no software R versão 4.1.2 (R CORE TEAM, 2018). A estatística $U_{t,T}$ contou o número de vezes que um membro da primeira amostra é maior que o membro da segunda (Eq. 8). A estatística $U_{t,T}$ é calculada para os valores de $1 < t < T$, e a estatística $k(t)$ é dada pela Equação 9.

$$U_{t,T} = U_{t-1,T} + \sum_{j=1}^T \text{sgn}(X_i - X_j) \quad (8)$$

$$k(t) = \text{MAX}_{1 \leq t \leq T} |U_{t,T}| \quad (9)$$

Em que: $\text{sgn}(x) = 1$ para $x > 0$; $\text{sgn}(x) = 0$ para $x = 0$; e, $\text{sgn}(x) = -1$ para $x < 0$.

O teste de Pettitt localiza o ponto em que ocorreu uma mudança abrupta na série histórica, o t onde ocorre o máximo de $k(t)$, resultando em K_{crit} , ou valores críticos (Eq. 10), na média de uma série temporal. Sua significância foi calculada pela Equação 9.

$$K_{crit} = \pm \sqrt{\frac{-\ln\left(\frac{p}{2}\right)(T^3 + T^2)}{6}} \quad (10)$$

$$p - \text{value} \cong 2 \exp\left\{\frac{-6k(t)^2}{(T^3 + T^2)}\right\} \quad (11)$$

4. RESULTADOS

4.1 MUDANÇAS NO USO E COBERTURA DO SOLO

As nomenclaturas das classes de uso e cobertura do solo podem ser encontradas na parte inferior da Tabela 1 e no rodapé da Tabela 2. As maiores extensões de área foram observadas para as classes EBF, SV, GL, WSV, WB, CL, PW, DBF, UBL e MF, de 3,37 M para 1,55 K km², respectivamente, enquanto ENF, DNF, OS e BN foram menores que 200 km², e CS e NVM, menores que 1000 km², representando menos que 0,02% do total. A classe PSI não foi observada (Tabela 2, Fig. 2).

Tabela 2 – Área, em km², das classes de uso e cobertura do solo da BLA entre 2009 e 2019.

Classes	ENF	EBF	DNF	DBF	MF	CS	OS	WSV
2009	126,49	3.374.351,77	0,74	9.370,81	2.685,39	313,90	170,61	219.487,50
2010	110,76	3.363.598,69	0,00	10.976,39	2.837,62	320,71	100,80	223.691,17
2011	114,47	3.356.746,45	0,00	11.235,69	2.671,78	332,30	64,89	226.820,70
2012	119,11	3.351.448,68	0,00	12.161,83	2.525,68	383,75	59,83	225.836,89
2013	132,59	3.346.877,56	0,00	12.592,50	2.292,61	419,95	60,18	225.740,05
2014	141,44	3.341.805,65	0,00	13.785,02	2.265,73	470,68	65,79	222.678,17
2015	144,93	3.332.142,23	0,00	15.043,02	2.275,90	525,03	86,63	218.875,11
2016	143,43	3.320.505,98	0,00	15.357,38	2.206,02	728,91	102,35	218.150,23
2017	157,83	3.318.989,15	0,24	16.228,36	2.122,46	830,99	98,89	212.146,05
2018	148,00	3.311.486,93	0,00	15.606,63	1.571,92	883,70	72,94	217.815,19
2019	122,77	3.307.899,08	0,00	16.282,29	1.554,08	823,63	59,67	219.497,52
Mínimo	110,76	3.307.899,08	0,00	9.370,81	1.554,08	313,90	59,67	212.146,05
Máximo	157,83	3.374.351,77	0,74	16.282,29	2.837,62	883,70	170,61	226.820,70
Média	132,89	3.338.713,83	0,09	13.512,72	2.273,56	548,50	85,69	220.976,23
Diferença	47,07	66.452,70	0,74	6.911,48	1.283,54	569,80	110,94	14.674,65
%	0,00	66,53	0,00	0,27	0,05	0,01	0,00	4,40
Classes	SV	GL	PW	CL	UBL	NVM	BN	WB
2009	814.410,32	427.688,15	42.969,10	46.468,92	3.214,24	760,86	118,81	76.486,03
2010	814.458,43	430.814,48	43.318,25	47.845,75	3.218,21	752,73	119,44	76.460,22
2011	820.451,11	424.921,60	44.032,14	50.617,98	3.222,43	775,05	114,60	76.502,45
2012	828.404,93	419.508,25	44.750,54	52.640,53	3.225,15	807,99	120,01	76.630,49
2013	831.246,14	418.879,58	45.302,60	54.131,14	3.227,63	837,67	121,21	76.762,25
2014	829.377,20	425.725,68	45.899,51	55.250,24	3.232,08	884,83	126,88	76.914,74
2015	825.109,87	440.198,42	46.546,19	56.517,91	3.234,31	892,63	139,62	76.891,86
2016	821.453,22	454.674,01	47.346,18	56.951,16	3.236,53	915,08	166,13	76.687,03
2017	814.680,05	466.125,38	46.820,45	59.371,91	3.241,23	867,62	177,82	76.765,22
2018	792.856,33	489.266,49	47.711,84	60.107,64	3.245,43	798,85	160,64	76.891,15
2019	777.734,68	504.234,83	47.931,70	61.454,07	3.249,64	668,03	142,10	76.969,55
Mínimo	777.734,68	418.879,58	42.969,10	46.468,92	3.214,24	668,03	114,60	76.460,22
Máximo	831.246,14	504.234,83	47.931,70	61.454,07	3.249,64	915,08	177,82	76.969,55
Média	815.471,12	445.639,72	45.693,50	54.668,84	3.231,53	814,67	137,02	76.723,73
Diferença	53.511,46	85.355,24	4.962,60	14.985,15	35,40	247,05	63,22	509,34
%	16,25	8,88	0,91	1,09	0,06	0,02	0,00	1,53

Nota: Florestas perenes de folhas estreitas (ENF); Florestas perenes de folhas largas (EBF); Floresta decíduas folhas estreitas (DNF); Floresta decíduas de folhas largas (DBF); Florestas mistas (MF); Arbustos fechados ou cerrado (CS); Arbustos abertos ou cerrado denso (OS); Savanas lenhosas (WSV); Cerrados (SV); Campos (GL); Pântanos ou pantanal (PW); Cultivos agrícolas (CL); Cidades ou área urbana (UBL); mosaicos de vegetação (NVM); Solo descoberto (BN); Corpos d'água (WB). Diferença: é a diferença entre a máxima e a mínima, caracterizando a mudança do período. %: é a porcentagem de área que cada classe representa, na média.

De forma geral, as classificações de uso e cobertura do solo com o produto MCD12Q1 apresentam boa precisão para a BLA ao longo dos anos estudados. Estudos relatam alta precisão na classificação de uso e cobertura do solo com o produto MCD12Q1, principalmente para classes mais estáveis, como corpos d'água e floresta (AHMAD *et al.*, 2022; BROWN *et al.*, 2022; CAÚLA *et al.*, 2017; HE *et al.*, 2022; SILVA *et al.*, 2023).

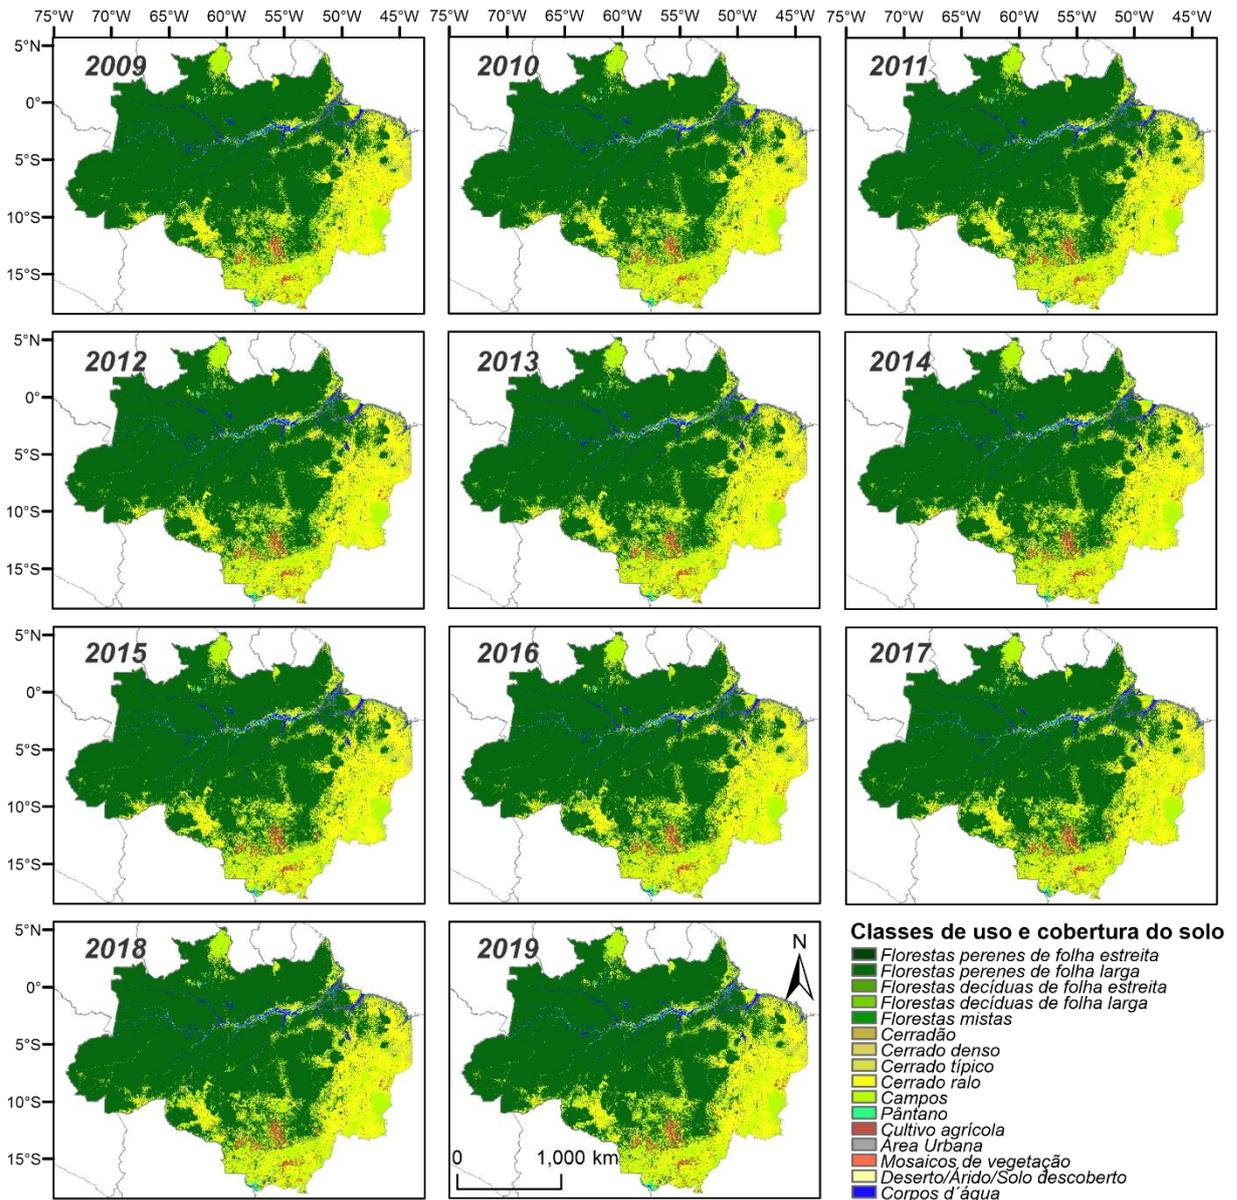


Figura 2 - Classes do uso e cobertura do solo na BLA entre 2009-2019.

De 2009 para 2019, houve acréscimos nas áreas das classes DBF (6.911,48 km²), CS (509,74 km²), WSV (10,02 km²), GL (76.546,68 km²), PW (4.962,60 km²), CL (14.985,15 km²), UBL (35,40 km²), BN (23,29 km²) e WB (483,52 km²) e diminuição nas áreas de ENF (3,72 km²), EBF (66.452,69 km²), MF (1.131,31 km²), OS (110,94 km²), SV (36.675,64 km²) e NVM (92,83 km²) (Tabela 2).

A EBF apresentou a maior área (3,34 M km²), sendo observada no centro, leste e norte da BLA. Também foi a que mais sofreu perdas ao longo da série temporal estudada, de 66.452,69 km². Considerando a área total de estudo, a classe EBF representava, 67,28% em 2009 e caiu para 65,95% em 2019. Isso evidencia uma redução de ~ 2%, com média anual de 6.645,27 km² na mudança do uso e cobertura do solo (Tabela 2, Fig. 2).

Nas regiões de nordeste a sul da BLA, foram observadas grandes áreas das classes SV, GL e WSV, representando a segunda, terceira e quarta maiores extensões, próximas umas às outras, principalmente na região do Arco do Desmatamento, uma transição entre biomas Amazônico-Cerrado. A classe SV foi observada do nordeste, perto de São Luís - MA, até o sul da BLA, e em parte no norte, região de Boa Vista – RO. As classes DBF e MF foram observadas próximas as classes SV, GL e WSV. Em concentração maior, DBF foi observada a sul do estado de Mato Grosso e na parte central do Maranhão e, MF, a SE de Mato Grosso e Pará (IBGE, 2021). CL foi a sexta maior em área e foi observada principalmente no sul da BLA (Fig. 1 e 2).

A SV também foi percebida próxima a WB, a quinta maior classe, e às rodovias federais em toda a área estudada, enquanto um forte destaque para GL foi observado no centro-leste do estado de Roraima. A maior representatividade dessas classes foi nos biomas Cerrado e Pantanal, principalmente nas transições para o bioma Amazônia (Fig. 1 e 2). Também foram observadas reduções para as áreas SV e WSV, de 53.511,46 km² de 2013 para 2019 e 14.674,65 km² de 2011 a 2017, respectivamente, enquanto foi observado um aumento para a classe GL após 2013 até 2019, de 85.355,24 km² (Tabela 1). As classes CS e OS foram observados adjacentes às classes DBF e MF, com pontos esparsos na região norte, leste e sul da BLA. A classe NVM foi fortemente relacionada à classe CL de forma que ambas foram observadas em maior quantidade de nordeste a sul (Fig. 2), também no Arco do Desmatamento.

A classe BN foi observada no leste da BLA, próxima aos rios Tocantins e Araguaia (classe WB), nas regiões em que a areia estavam expostas, formando praias (IBGE, 2020, 2021). A classe PW apareceu relacionada a classe WB de forma adjacente, e foram observadas em toda a extensão da área estudada em formatos contínuos ramificados, representadas pelos grandes rios da região, como o Amazonas, Negro, Solimões, Araguaia e Tocantins (classe WB). A classe UBL também foi observada em toda a extensão da área estudada em pequenos pontos dispersos. A classe DNF foi observada na região noroeste da BLA, ao norte do município de Barcelos - AM, na interseção ao sul entre as UC Parque Estadual Serra do Aracá e Floresta Nacional do Amazonas (IBGE, 2020, 2021). Estes pontos foram observados apenas em 2009 e 2017, e representaram uma diminuição de 0,50 km² em área (Fig. 1 e 2).

A Figura 3 destaca o distrito de Santo Antônio do Matupi (estado do Amazonas) comparando os anos de 2009 (Fig. 3A e C) e 2019 (Fig. 3B e D). Este é um exemplo típico de uma mudança maior do uso e cobertura do solo de florestas para áreas antropizadas. O distrito de Santo Antônio do Matupi fica localizado no Município de Manicoré, ao sul do Estado do Amazonas, fazendo divisa com os Estados de Mato Grosso e Rondônia, próximo à rodovia federal “Transamazônica 230” (IBGE, 2020, 2021). Conforme mencionado, este local foi especialmente escolhido por apresentar significativas perdas florestais, principalmente da classe EBF e o aumento de áreas antropizadas ou de transição, classes SV, GL e WSV, mais intensas no entorno da rodovia “Transamazônica 230”.

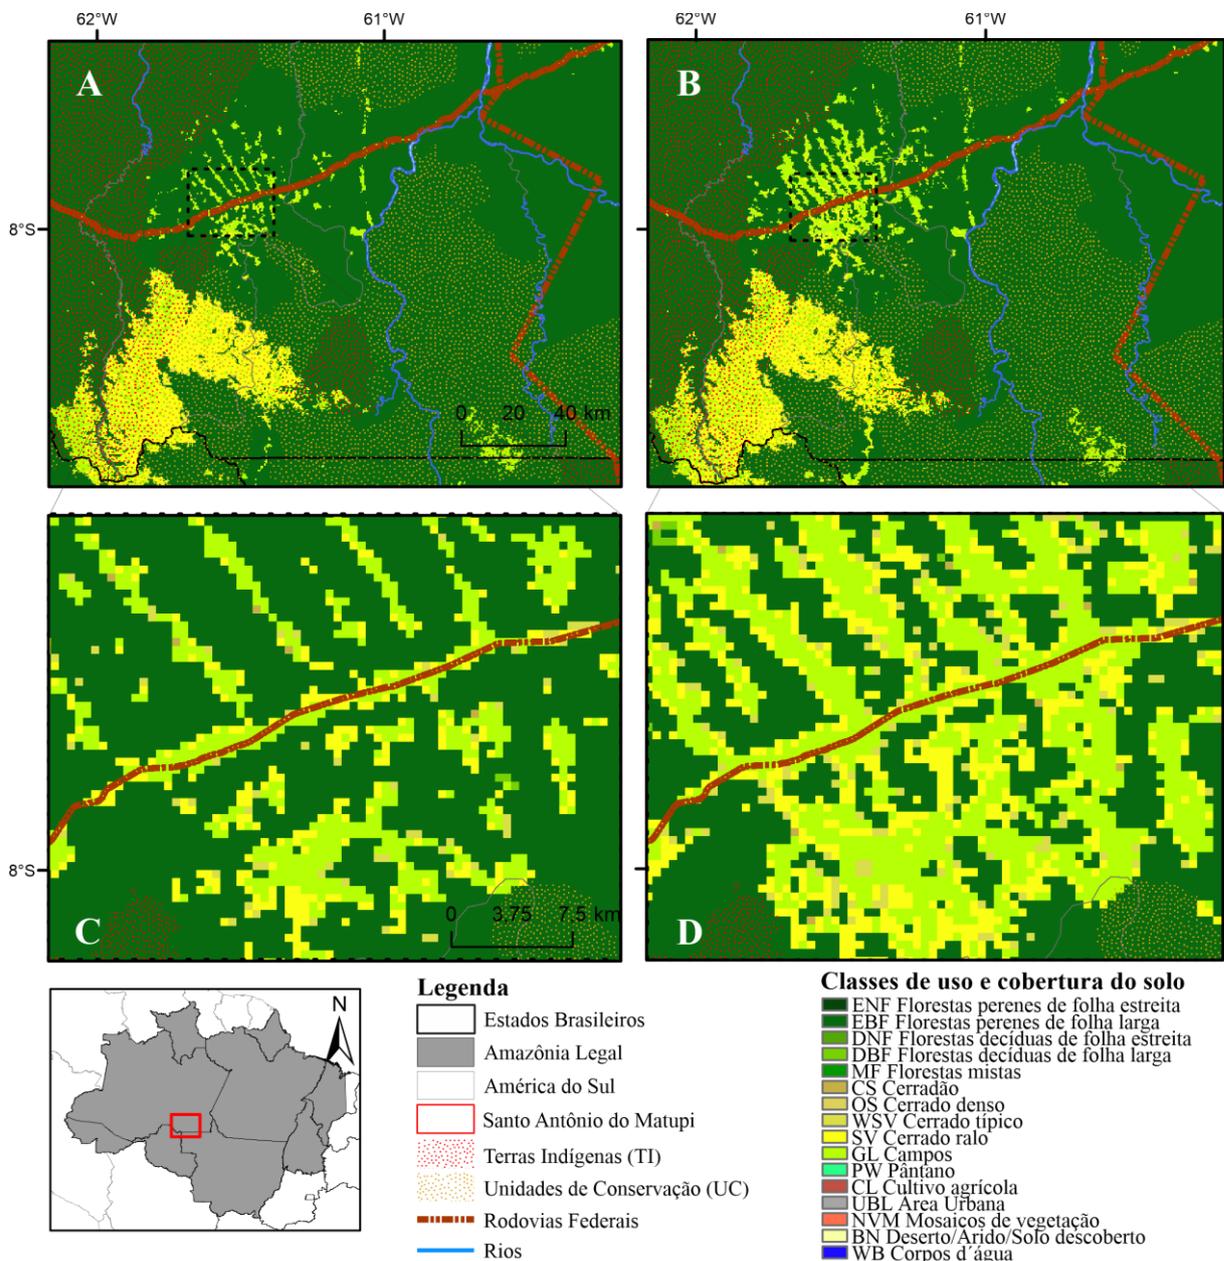


Figura 3 – Mudança no uso e cobertura do solo no distrito de Santo Antônio do Matupi, município de Manicoré - AM, para 2009 (A) e sua versão ampliada (C), e para 2019 (B) sua versão ampliada (D)

O distrito de Santo Antônio do Matupi se localiza ao norte das UC Parque Nacional dos Campos Amazônicos e Floresta Nacional do Aripuanã e ao sul da Área de Proteção Ambiental Campos de Manicoré e Reserva Biológica de Manicoré (BRASIL, 2016). Tal mudança de uso e cobertura do solo está próxima às TI Diahui, Pirahã, Sepoti, Tenharim Marmelos e Tenharim do Igarapé Preto, as quais também estão em zonas de preservação ambiental, ecológica e social (QIN *et al.*, 2023). No entanto, Santo Antônio do Matupi é um importante centro madeireiro. Perdas de florestas primárias foram observadas em Santo Antônio do Matupi, com o período mais crítico de taxas de desmatamento registrado entre 2004 e 2018, quando 63,28% da área foi convertida em pastagens (DUARTE *et al.*, 2021). Em 2010, foi uma das dez comunidades mais contribuintes com a economia do Amazonas; em 2014, a quarta maior produtora de gado do estado e a maior produtora de madeira, com aumento de rebanho de 800% e área desmatada em mais de 676,5 km² (DUARTE *et al.*, 2021; WENZEL, 2020).

Das áreas observadas com mudanças significativas no uso e cobertura do solo durante a série temporal analisada no presente trabalho, a maioria está próxima a TIs (BEGOTTI; PERES, 2019). As principais concentrações de TIs foram observadas nos estados do Amazonas, 165 TIs, Mato Grosso, com 80 TIs, e Pará, com 65 TIs, no entanto, as mais prejudicadas foram, ao norte de Roraima, as TIs Ananás, Anaro, Aningal, Anta, Araçá, Barata Livramento, Bom Jesus, Boqueirão, Cajueiro, Canauanim, Jabuti, Jacamim, Malacacheta, Mangueira, Manoa/Pium, Moskow, Muriru, Ouro, Pium, Ponta da Serra, Raimundão, Raposa Serra do Sol, Santa Inez, São Marcos, Serra da Moça, Sucuba, Tabalascada, Truaru, importantes abrigos para as etnias Taulipáng, Makuxí, Ingarikó, Wapixana.

Ao norte do estado do Pará, a TI Parque do Tumucumaque protege as etnias Wayana e Apalaí. A NE, as etnias Amanayé, Anambé, Timbira e Tembé; entre as rodovias BR-230 e BR-364, as etnias Arara do Pará, Araweté, Asurini do Xingu, Kayapó, Kuruáya e Parakanã foram encurraladas; e, ao S, parte do solo indígena Munduruku, que habita os Mundurukús, foram afetadas (FUNAI, 2019; IBGE, 2020, 2021).

Também, ao norte do estado do Amapá, na TI Uaçá, onde vivem os Karipunas, tem sofrido pressões causadas por mudanças no uso e cobertura do solo. No estado do Maranhão, foram prejudicadas as etnias Gavião Pukobiê, Guajá, Kanela, Krikati, Tenetehara e Timbira. No estado do Tocantins, as etnias Apinayé, Ava-Canoeiro, Javaé, Ka'apor, Karajá, Krahô, Tapirapé e Xerente também foram afetadas (FUNAI, 2019; IBGE, 2020, 2021).

No estado de Mato Grosso, todas as terras indígenas ao sul foram afetadas, prejudicando as etnias Bakairí, Boróro, Chiquitáno, Guató, Halotesu, Nambikwára, Paresí, Umutina, Wasusu e Xavante, com destaque para os Boróros, Paresís e Xavantes que sofreram grandes reduções

em seu povoado. A leste de Mato Grosso ainda há uma grande ameaça aos Aweti, Ikpeng, Kaiabi, Kalapalo, Kamayurá, Karajá, Kayapó, Kisêdjê, Kuikuro, Matipú, Mehináku, Nahukuá, Tapayuna, Tapirapé, Trumái, Wauja, Xavantes, Yawalapití, Yudjá; e, a NW, as etnias Apiaká, Cinta Larga, Enawenê-Nawê, Irántxe, Kaiabi, Mynky, Rikbaktsa, Suruí de Rondônia e Zoró estão sob ameaça das novas fronteiras agrícolas e do desmatamento (BEGOTTI; PERES, 2019; FUNAI, 2019; IBGE, 2020, 2021; ROSSI *et al.*, 2022).

Embora os índios detenham a posse permanente e o usufruto exclusivo das riquezas do solo, dos rios e dos lagos existentes em suas terras, conforme o parágrafo 2º do Artigo 231 da Constituição, elas constituem patrimônio da União. E, como bens públicos de uso especial, as terras indígenas, além de inalienáveis e indisponíveis, não podem ser objeto de utilização de qualquer espécie por outros que não os próprios índios (FUNAI, 2019; IBGE, 2020, 2021), ou seja, o desmatamento deveria ser zero, e as mudanças no uso e cobertura do solo verificadas nessas áreas se constitui uma infração da lei.

4.2 VARIABILIDADE ESPACIAL DO CARBONO

Maiores valores de GPP foram encontrados nas regiões oeste, centro e norte da BLA, entre 40 e 44 gC m⁻², como pode ser visto principalmente na classe EBF (Fig. 2 e 4). Os valores máximos de GPP, representados pela cor azul marinho, foram encontrados no nordeste da BLA, nas regiões do estado do Amapá e noroeste do Pará, próximas à linha do equador (IBGE, 2020, 2021), com máximas entre 80,55 gC m⁻² (2009) e 88,2 gC m⁻² (2015). Valores próximos a zero foram observados próximos aos limites de leste a sul e no estado de Roraima. No ano de 2016, observou-se a maior intensidade de valores e maior extensão em relação aos demais anos, representado pela coloração alaranjada mais acentuado no SE e relacionado com as classes SV, GL e WSV. Além disso, MF, SV e WSV diminuíram em extensão enquanto GL, CL, UBL, PW e WB aumentaram. Essas mudanças de uso e cobertura do solo estiveram relacionadas com a diminuição nos valores de GPP no período estudado (Fig. 4; Tabela 1).

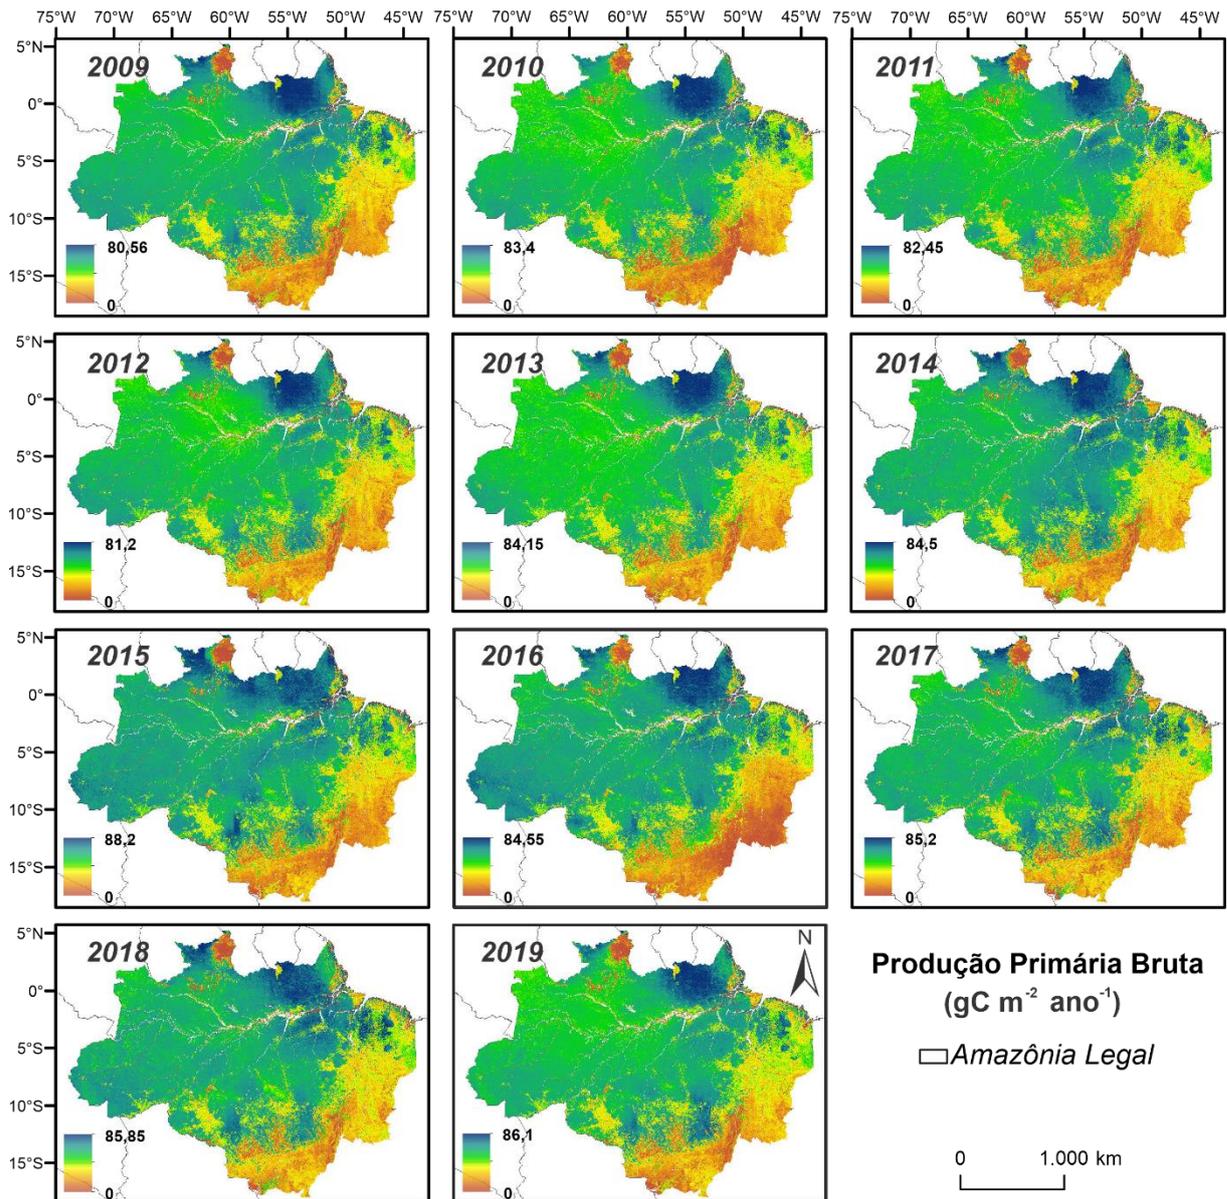


Figura 4 – Produção primária bruta (gC m⁻² ano⁻¹) na Amazônia Legal entre 2009 e 2019.

Os valores mais baixos de CO₂Flux foram encontrados nas regiões central e oeste da BLA. Tais valores, muitas vezes negativos, foram representados pelas classes florestais EBF, DBF, MF e WSV, sendo a EBF a principal devido à sua extensão. No centro da área de estudo, foram observadas maiores absorções de carbono, principalmente em 2019, de -8,35 μmol m⁻²s⁻¹, para a classe EBF, semelhante ao observado por Rossi et al. (2022) em 2017. Os maiores valores de CO₂Flux foram observados na transição de nordeste para sul, onde se localizam as classes SV, GL, CL e PW (Fig. 5).

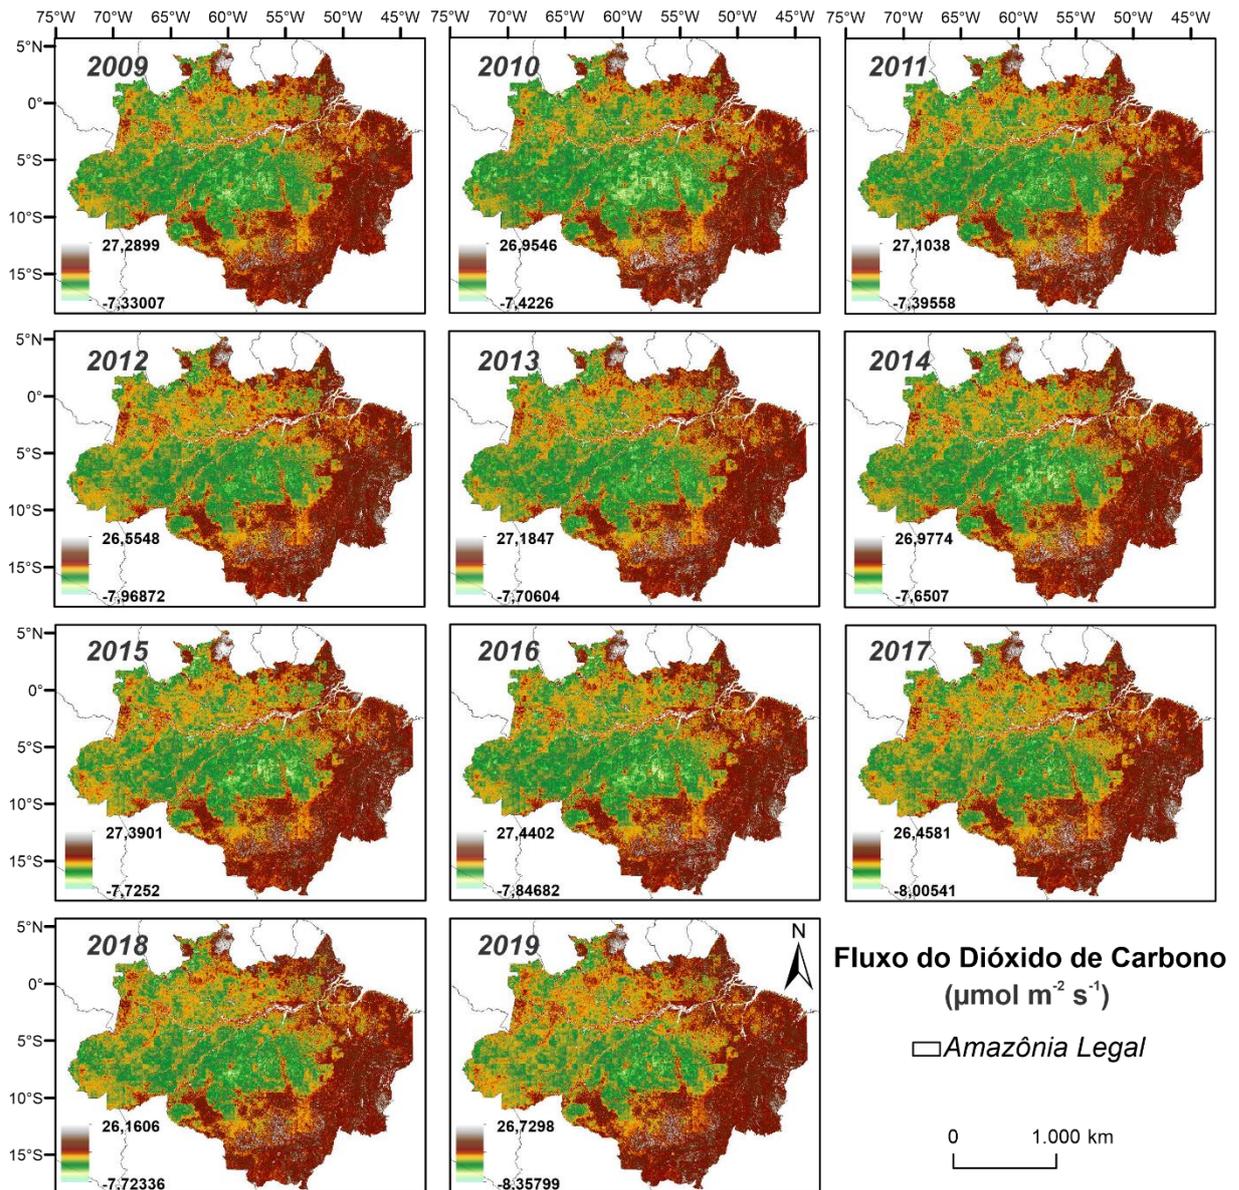


Figura 5 – Fluxo de dióxido de carbono ($\mu\text{mol m}^{-2} \text{s}^{-1}$) na Amazônia Legal entre 2009 e 2019.

A distribuição espacial dos pontos quentes de XCO_2 se concentrou na região central e SE da BLA, onde o agrupamento dos valores altos e mais intenso retornaram *hotspots* (Fig. 6). Assim como observado para GPP (Fig. 4), em 2009 e 2016, a região SE apresentou grande concentração de *hotspots* de 99% de confiança, os quais foram frequentes para a maioria dos anos estudados. Nas regiões centro-norte do estado de Mato Grosso, os *hotspots* foram observados em 2015 e 2016 e apresentaram padrões atmosféricos espaciais de XCO_2 mais elevados do que 2017 e 2018 (Fig. 6).

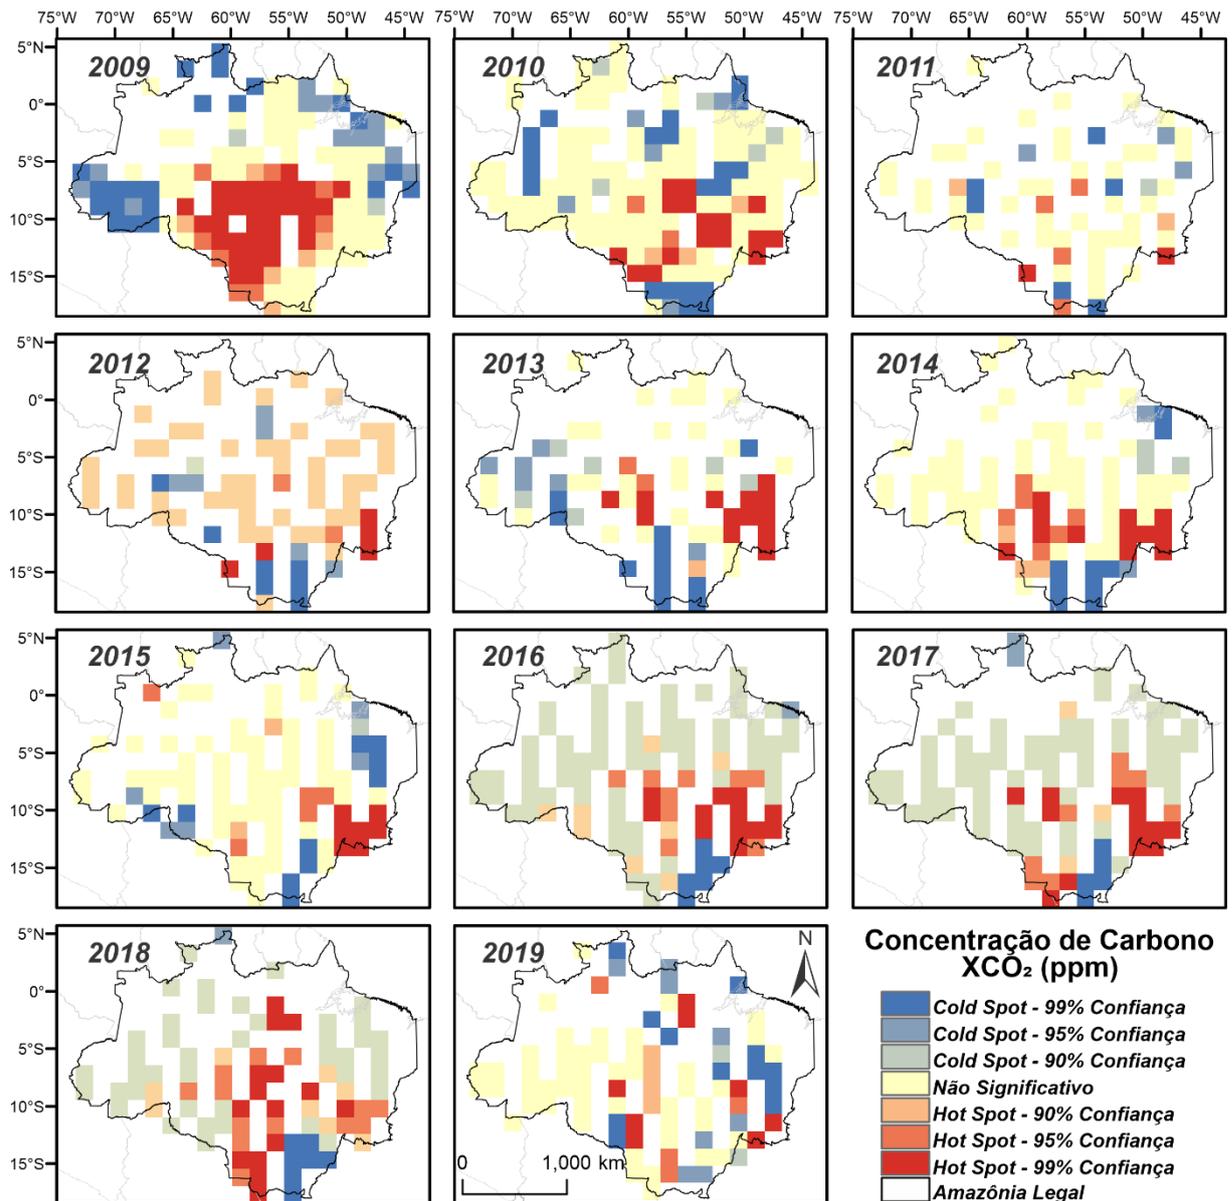


Figura 6 – Hotspot para concentrações atmosféricas (XCO_2) recuperadas de dados GOSAT na Amazônia Legal entre 2009 e 2019.

Por outro lado, os pontos frios foram distribuídos principalmente do norte a oeste da BLA, e em partes ao sul, como visto para os valores negativos de CO_2 Flux e positivos de GPP. Esses representam os valores negativos significativos que resultaram em agrupamento mais intenso de valores baixos, os *coldspots*, em área tipicamente florestal, como a classe EBF. Os *coldspots* foram observados de 2010 a 2018, também na região sul, com destaque para os anos de 2016 a 2018 em que teve grande porcentagem de *coldspots* a nível de 90% de confiança, o que contrastou com anos anteriores (Fig. 6).

Os valores de concentrações atmosféricas de CO₂ na BLA, nos anos de 2009 a 2019, foram de 384,3, 387,27, 387,83, 391,18, 393,84, 393,93, 397,97, 401,08, 402,29, 404,53 e 408,15 ppm, respectivamente, apontando um aumento entre de 2,2 a 2,8 ppm anualmente.

Para todos os anos estudados, as porções central, oeste e norte da BLA obtiveram maiores precipitações, com exceção do extremo norte, no estado de Roraima. As máximas anuais foram observadas no noroeste para todos os anos e no nordeste para os anos de 2009 a 2013 e 2017 a 2019. As precipitações mínimas foram encontradas na região de leste a sul, para os anos de 2015 a 2017. A menor precipitação foi em 2015, de 618,60 mm, devido a um evento de seca severa na Amazônia (ARAGÃO et al., 2018) (Fig. 7).

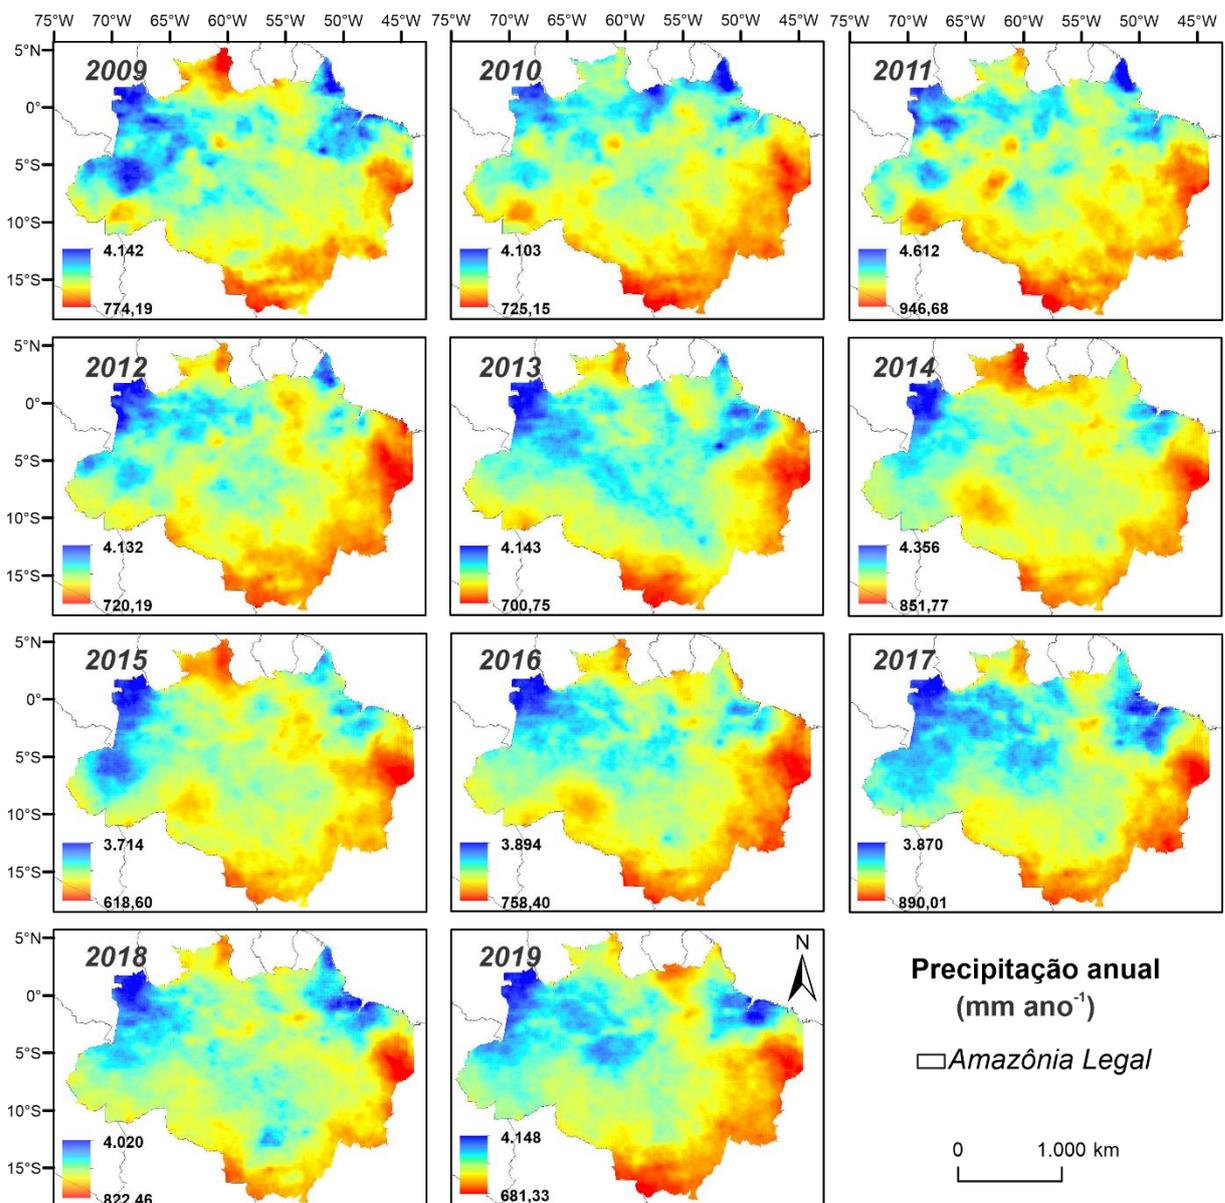


Figura 7 - Precipitação anual (mm ano⁻¹) na Amazônia Legal entre 2009 e 2019.

Os valores máximos de precipitação foram encontrados nas regiões do estado do Amapá e noroeste do Amazonas e nordeste do Pará, próximas à linha do equador, exceto para 2014 a 2016 e 2019, para o estado do Amapá (Fig. 7).

4.3 ANÁLISE ESTATÍSTICA

Conforme a Tabela 3, o não agrupamento demonstrou distribuição não normal para as variáveis, pois apresentaram $p\text{-value} > 5\%$ pelo teste de Shapiro-Wilk (HERVÉ, 2016). No entanto, os dados se apresentaram normais quando agrupados em ano, para GPP e maior parte da variável Chuva, também quando agrupados em classes, para CO₂Flux e Chuva. Não foi possível verificar a normalidade do agrupamento em classes para GPP porque os dados de WB e UBL apresentaram valores nulos, pois não representam classes vegetativas.

Tabela 3 – $p\text{-value}$ do teste multivariado de normalidade de Shapiro-Wilk não agrupado e agrupado por classes e anos para as variáveis GPP, CO₂Flux e Chuva.

Variável	Agrupado por classes										
	Não agrupado	EBF	DBF	MF	WSV	SV	GL	PW	CL	UBL	WB
GPP	0,00***	-	-	-	-	-	-	-	-	-	-
CO₂Flux	0,00***	0,00***	0,94	0,66	0,20	0,87	0,05**	0,47	0,01***	0,69	0,46
Chuva	0,00***	0,79	0,79	0,44	0,95	0,23	0,58	0,08*	0,70	0,12	0,42
Agrupado por anos											
	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
GPP	0,48	0,41	0,44	0,39	0,51	0,57	0,47	0,49	0,48	0,42	0,40
CO₂Flux	0,00***	0,01***	0,00***	0,01***	0,00***	0,01***	0,01***	0,01***	0,01***	0,01***	0,01***
Chuva	0,19	0,82	0,72	0,21	0,01***	0,02**	0,00***	0,01***	0,06*	0,06*	0,14

*, ** e ***: significativos a 10, 5 e 1% de probabilidade pelo teste de normalidade de Shapiro-Wilk.

O não agrupamento foi sensível à normalidade, no entanto, o teste de normalidade agrupado conseguiu identificar as classes ou anos responsáveis pela distribuição heterogênea em relação ao centro (MACFARLAND; YATES, 2021). O agrupamento demonstrou ser mais assertivo para os dados analisados (HERVÉ, 2016) e ser o mais recomendado para este tipo de avaliação (CHEN; WANG; XIE, 2023; HERVÉ, 2016; MACFARLAND; YATES, 2021).

As classes EBF, GL e CL representaram as maiores variabilidades para CO₂Flux, e PW, para Chuva, nos anos de 2013 a 2018. O teste de normalidade agrupado de Shapiro-Wilk indicou que as estatísticas poderiam ser aplicadas à distribuição normal de dados para GPP ou Chuva ao longo dos anos. O mesmo ocorreu no caso da variável Chuva em diferentes classes de uso e cobertura do solo (Tabela 3).

Complementarmente ao teste de normalidade de Shapiro-Wilk, os histogramas para GPP, CO₂Flux e Chuva mostraram a distribuição dos dados e em que posição estava sua maior frequência. A maior frequência foi observada entre 20 e 40 gC m⁻², para GPP, -1,0 e 2,5 μmol m⁻² s⁻¹, para CO₂Flux, e de 1.600 a 2.200 mm, para Chuva. Com base no histograma, também foi possível identificar possíveis problemas com valores e tendências inesperadas (Fig. 8).

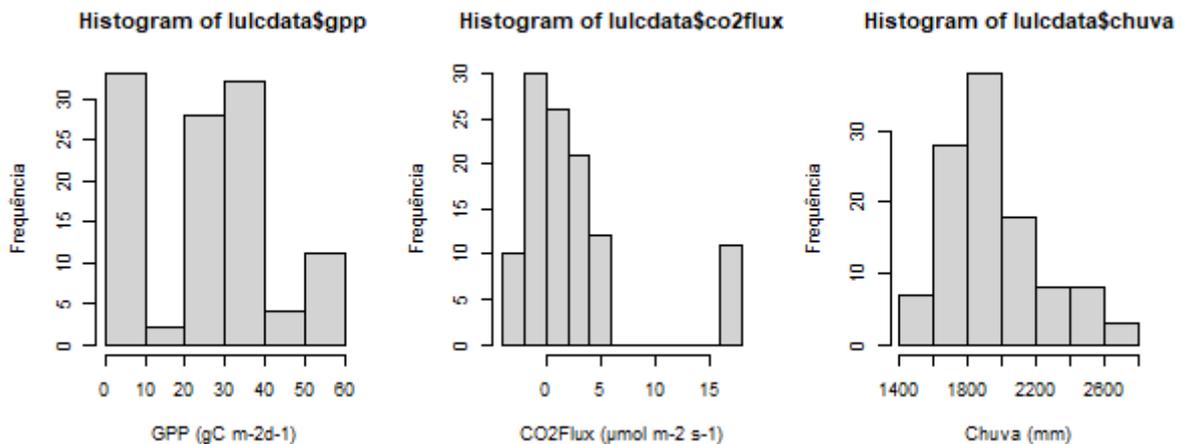


Figura 8 – Histograma da frequência de distribuição dos dados de GPP, CO₂Flux e Chuva.

Foi possível compreender, pelo histograma, que havia irregularidade nos dados à medida que se afastam do centro, sugerindo que os dados não eram paramétricos (MACFARLAND; YATES, 2021), como parece ser comum para este tipo de estudo (CAMARRETTA *et al.*, 2021; DÍAZ ARANGO, 2023; ZHANG *et al.*, 2021a). Considerando esses fatos, foi utilizada a mediana, pois é a mais recomendada para comparar grupos em relação à média dos valores (DIRIKOLU *et al.*, 2023; KROEGER *et al.*, 2022).

Como o teste multivariado de normalidade Shapiro-Wilk e o histograma (Tabela 3 e Fig. 8) apresentaram dados não paramétricos (KROEGER *et al.*, 2022; MACFARLAND; YATES, 2021), como é comum em trabalhos de campo e dados climáticos (CAMARRETTA *et al.*, 2021; DÍAZ ARANGO, 2023; ZHANG *et al.*, 2021a), decidiu-se aplicar os testes Kruskal-Wallis e Dunn para comparar grupos de classes. Foram realizados os *boxplots* agrupados por classes e por anos (Fig. 9). Os valores medianos dos agrupamentos classes e ano foram utilizados por serem mais recomendável para comparação dos grupos em relação às médias (DIRIKOLU *et al.*, 2023; KROEGER *et al.*, 2022) e foram apresentados na Tabela 4.

Diferenças entre as classes de uso e cobertura do solo foram observadas para GPP ($X^2 = 103,96$), CO₂Flux ($X^2 = 106,73$) e Chuva ($X^2 = 65,12$) pelo teste de Kruskal-Wallis ($p < 0,05$). O teste de *post-hoc* de Dunn mostrou que essas diferenças, na variável GPP, foram entre EBF

e CL, GL, UBL, PW e WB. As classes DBF e WSV foram diferentes de UBL, PW e WB e WSV também diferiu de CL, enquanto MF e SV foram diferentes de UBL e WB. Também é interessante observar que EBF não diferiu das classes DBF, MF, SV e WSV, todas consideradas classes florestais, que tiveram medianas de 52,90, 34,68, 31,53, 31,32 e 39,84 gC m^{-2} . *Outliers* abaixo dos valores mínimos foram observados para SV, DBF, CL e PW, de 23,53, 22,90, 16,88 e 0,43 gC m^{-2} , em 2016, respectivamente (Fig. 9a e Tabela 4).

A classe EBF apresentou o maior valor de mediana em relação às outras classes, de 52,9 gC m^{-2} e um *outlier* acima do máximo de 55,43, em 2018. A classe PW teve os menores valores de GPP, de 0,6 gC m^{-2} . As quantidades de carbono total absorvidas das áreas, relacionadas com cada uma de sua extensão foram, em média, de 176,63, 25,54, 11,46, 8,80, 1,17, 0,47 e 0,07 Tg C ano^{-1} para as classes EBF, SV, GL, WSV, CL, DBF e MF, respectivamente. UBL e WB não absorveram nenhum carbono, pois não representam áreas de vegetação, e a classe PW absorveu apenas 0,03 Tg C ano^{-1} (Fig. 9a e Tabela 4).

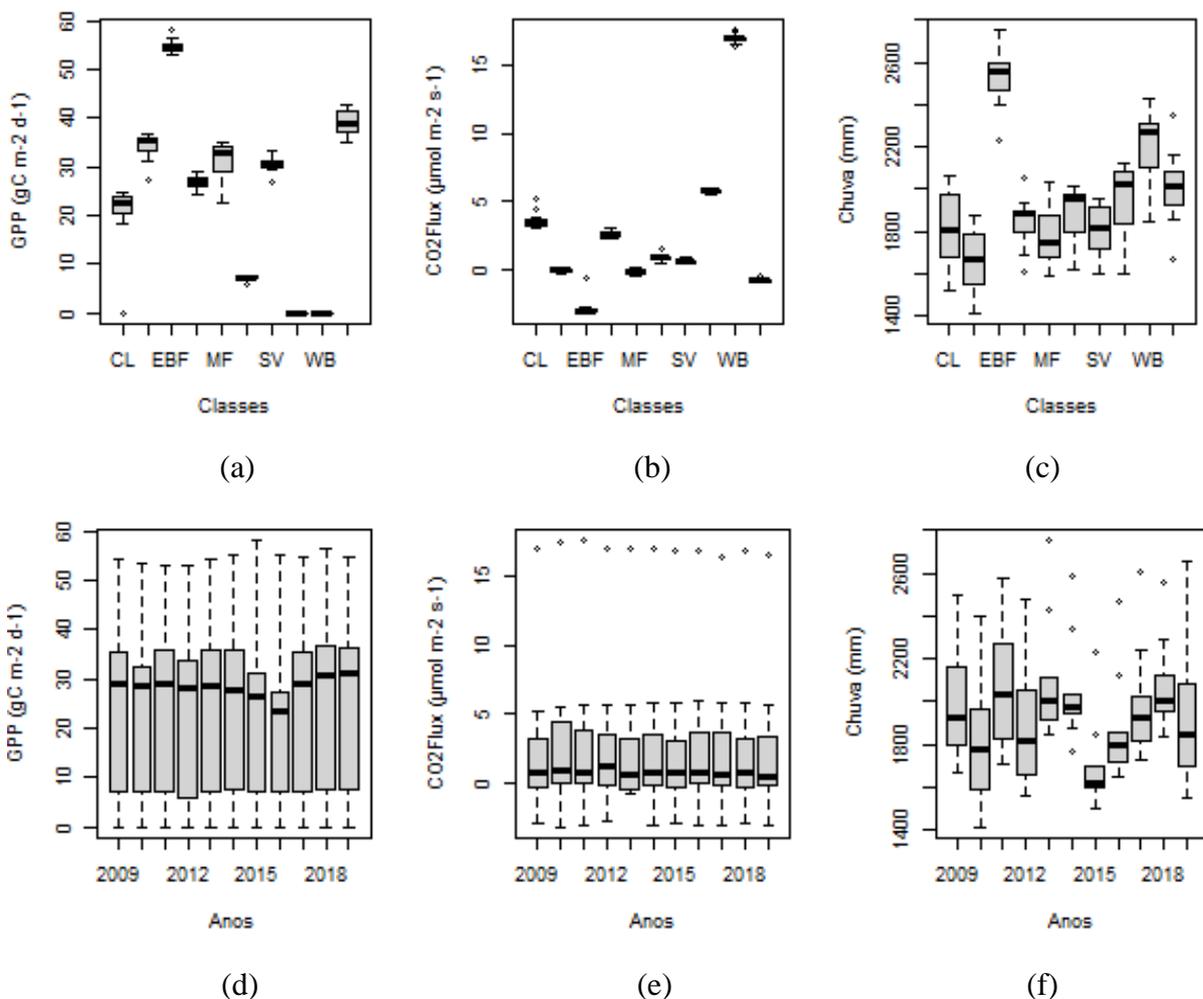


Figura 9 – Boxplot da mediana, quartis de 25% e 75%, e dados de *outliers* para classes (em ordem alfabética, CL, DBF, EBF, MF, GL, PW, SV, UBL, WB e WSB) das variáveis (a) GPP, (b) CO₂Flux e (c) Chuva, e por anos, para (d) GPP, (e) CO₂Flux e (f) Chuva.

Para a variável CO₂Flux, o teste de Dunn e o *boxplot* apontaram diferença entre EBF e CL, GL, UBL, PW e WB, como observado em GPP, e semelhança as classes florestais DBF, MF e WSV, exceto para SV, com valores de -3,09, -0,06, -0,26, -0,65 e 0,28 $\mu\text{mol m}^{-2} \text{s}^{-1}$, respectivamente. As classes DBF e MF foram diferentes de CL, UBL e WB. A classe WSV foi diferente de CL, GL, SV, UBL, PW e WB, enquanto SV foi diferente também de WB. PW foi diferente de WB, mas semelhante a UBL (Fig. 9b; Tabela 4).

Tabela 4 – Estatística descritiva dos dados de GPP, CO₂Flux e Chuva, para cada uso e cobertura do solo na Amazônia Legal, entre 2009 e 2019.

Classes	GPP (gC m^{-2})											Média	Dif.
	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019		
EBF	51,53	51,98	51,78	51,53	50,23	53,88	55,20	54,50	53,48	55,43	52,45	52,90	5,20
DBF	34,63	33,38	38,55	33,15	36,58	37,43	30,90	22,90	36,05	39,20	38,75	34,68	16,30
MF	32,65	29,00	30,43	34,33	32,93	28,95	28,95	22,35	36,23	35,80	35,23	31,53	13,88
WSV	40,15	36,63	39,70	38,08	41,73	39,68	39,25	35,53	42,50	43,10	41,93	39,84	7,58
SV	33,30	31,28	31,13	30,88	30,43	32,78	28,00	23,53	31,30	35,90	36,00	31,32	12,48
GL	26,43	29,15	28,23	23,60	22,60	26,80	23,70	16,25	25,48	29,30	31,25	25,71	15,00
PW	0,45	0,60	0,65	0,65	0,60	0,73	0,55	0,43	0,65	0,65	0,65	0,60	0,30
CL	22,85	19,05	21,63	21,65	20,68	22,35	21,00	16,88	22,78	23,00	24,03	21,44	7,15
UBL	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
WB	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Classes	CO ₂ Flux ($\mu\text{mol m}^{-2} \text{s}^{-1}$)											Média	Dif.
	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019		
EBF	-2,95	-3,55	-3,07	-2,88	-1,44	-3,55	-3,23	-3,17	-3,13	-3,47	-3,50	-3,09	2,11
DBF	-0,28	0,05	-0,07	0,09	-0,16	-0,13	0,06	0,04	-0,17	-0,07	0,03	-0,06	0,37
MF	-0,39	0,11	-0,14	-0,22	-0,48	-0,06	-0,43	-0,09	-0,28	-0,53	-0,39	-0,26	0,65
WSV	-0,89	-0,54	-0,97	-0,51	-0,48	-0,98	-0,44	-0,57	-0,31	-0,74	-0,72	-0,65	0,66
SV	0,13	0,57	0,22	0,69	0,31	-0,08	0,38	0,61	0,15	0,11	0,01	0,28	0,77
GL	3,74	2,47	2,13	2,51	2,69	3,70	2,55	2,72	2,76	2,98	2,85	2,83	1,61
PW	0,42	1,00	0,93	0,97	0,43	1,00	0,74	0,76	0,72	0,67	0,43	0,73	0,58
CL	3,32	4,93	3,63	3,24	3,07	3,69	2,98	3,47	3,57	3,13	3,45	3,50	1,94
UBL	5,19	5,69	5,98	5,63	5,91	5,80	5,87	5,97	5,84	5,87	5,66	5,76	0,78
WB	15,69	17,28	16,09	16,41	16,93	15,85	15,04	15,44	15,25	15,66	15,44	15,92	2,24
Classes	Chuva (mm)											Média	Dif.
	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019		
EBF	2.402	2.360	2.507	2.569	2.792	2.446	2.163	2.430	2.581	2.435	2.522	2.473	629,00
DBF	1.750	1.475	1.740	1.491	1.941	1.940	1.546	1.660	1.784	1.903	1.554	1.708	465,88
MF	1.769	1.528	1.780	1.677	2.016	1.910	1.643	1.716	1.819	1.978	1.598	1.767	487,93
WSV	2.129	1.810	2.182	1.788	2.023	2.109	1.706	1.764	1.852	1.880	1.846	1.917	476,18
SV	1.767	1.584	1.677	1.771	1.983	1.763	1.530	1.716	1.831	1.854	1.562	1.731	453,04
GL	2.091	1.808	2.018	1.798	1.848	1.680	1.533	1.605	1.749	1.856	1.758	1.795	558,63
PW	2.025	1.702	2.098	1.765	2.005	1.976	1.707	1.806	1.826	2.051	1.959	1.902	395,94
CL	1.785	1.527	1.897	1.682	1.815	1.942	1.563	1.688	1.884	2.074	1.658	1.774	547,42
UBL	1.935	1.830	2.061	1.885	2.046	1.999	1.605	1.679	1.999	2.057	2.120	1.929	515,66
WB	2.378	1.976	2.318	1.944	2.453	2.395	1.895	2.292	2.446	2.170	2.310	2.234	557,56

Florestas perenes de folhas estreitas (ENF); Florestas perenes de folhas largas (EBF); Floresta decíduas folhas estreitas (DNF); Floresta decíduas de folhas largas (DBF); Florestas mistas (MF); Arbustos fechados ou cerradão (CS); Arbustos abertos ou cerrado denso (OS); Savanas lenhosas (WSV); Cerrados (SV); Campos (GL); Pântanos ou pantanal (PW); Cultivos agrícolas (CL); Cidades ou área urbana (UBL); mosaicos de vegetação (NVM); Solo descoberto (BN); Corpos d'água (WB). Dif.: é a diferença entre a máxima e a mínima, caracterizando a mudança do período.

As classes DBF, MF e SV, oscilaram entre valores negativos e positivos, enquanto PW foi positivo, porém, também se mantendo próximos a zero. Certamente estes valores fizeram

que DBF e MF fossem mais semelhantes, assim como aconteceu para SV e PW, pois os valores de CO₂Flux aumentaram de classes florestais para classes de uso antrópico, seguindo a ordem EBF, WSV, MF, DBF, SV, PW, GL, CL e UBL (Fig. 9b; Tabela 4). Estas três últimas classes atuaram como principais fontes de emissões de CO₂ nas mudanças de usos do solo (ROSSI *et al.*, 2021), diminuindo a quantidade de C absorvido por florestas por diminuição de suas áreas através do desmatamento (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005).

Na variável Chuva, o teste de Dunn afirmou que houve diferença entre EBF e DBF, CL, GL, MF, SV e PW, mas não para UBL e WB, que tiveram valores acima de 1.605 mm. Além disso, as classes DBF, MF e SV também diferiram de WB, mas DBF também foi diferente de WSV, isso por que DBF, MF, SV, GL e CL foram as classes de menor precipitação, com valores abaixo de 1.533 mm. WSV, PW e UBL tiveram médias entre 1.902 e 1.929 mm enquanto nas classes EBF e WB foram de 2.473 e 2.234 mm (Fig. 9c; Tabela 4).

A análise de cluster foi realizada para melhorar a visualização dos agrupamentos, a qual demonstrou que EBF foi o agrupamento mais distantes dos usos e cobertura da BLA, e que mais se aproximou de DBF e WSV para as variáveis capazes de mensurar a absorção e estoque de carbono acima do solo, sendo finalmente agrupados de acordo com o regime pluviométrico destas classes (Fig. 10). Juntas, estas classes representaram a maior absorção de carbono (RAJU *et al.*, 2023).

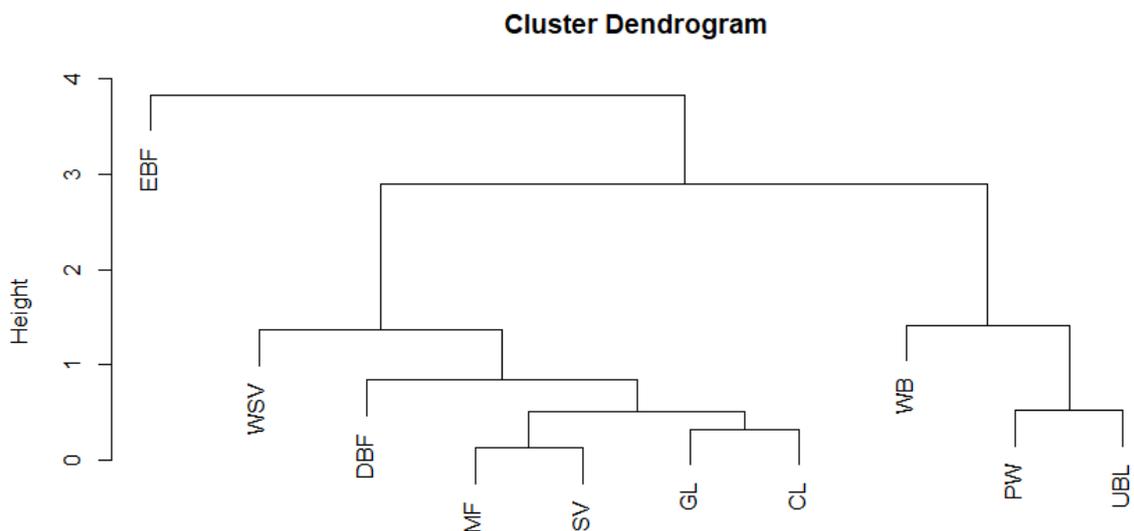


Figura 10 – Análise de cluster entre as variáveis GPP, CO₂Flux e Chuva escaladas, nos diferentes uso e cobertura do solo. Florestas perenes de folhas largas (EBF); Floresta decíduas de folhas largas (DBF); Florestas mistas (MF); Savanas lenhosas (WSV); Cerrados (SV); Campos (GL); Pântanos ou pantanal (PW); Cultivos agrícolas (CL); Cidades ou área urbana (UBL); Corpos d’água (WB).

As classes GL e CL foram semelhantes entre si porque, apesar de representarem valores medianos de GPP, de 25,71 e 21,44 gC m⁻², os valores de CO₂Flux foram sempre positivos, de 2,83 e 3,50 μmol m⁻² s⁻¹, respectivamente, indicando emissões de CO₂ (ROSSI *et al.*, 2021).

Este grupo só perdeu para UBL e WB, que representaram as maiores emissões através de CO₂Flux, de 5,76 e 15,92 $\mu\text{mol m}^{-2} \text{s}^{-1}$, respectivamente, e nenhuma produção de biomassa. PW se juntou a este último grupo (WB e UBL) principalmente por não produzir biomassa eficientemente, de apenas 0,6 gC m^{-2} ao longo dos anos (Fig. 9a,b, 10; Tabela 4).

As classes MF e SV foram semelhantes porque produziram mais biomassa, de 31,53 e 31,32 gC m^{-2} , que os grupos GL e CL, porém, oscilaram entre absorção e emissão de carbono por CO₂Flux, entre 0,11 a -0,53 e 0,69 e -0,08 $\mu\text{mol m}^{-2} \text{s}^{-1}$, respectivamente, bem como é observado para DBF com GPP apenas um pouco maior, de 34,68 gC m^{-2} . A classe WSV apresentou maiores produção de biomassa em relação as classes anteriores, de 39,84 gC m^{-2} , mas absorveu carbono todos os anos (CO₂Flux < 0), assim como EBF. No entanto, esta última classe foi a que obteve maior absorção de carbono por GPP e CO₂Flux, aliada a maior quantidade de Chuvas em relação as demais classes (Fig. 9a,b,c, e 10).

Nos testes de Kruskal-Wallis e de Dunn para comparação entre os anos na BLA, apenas a variável Chuva apresentou diferença significativa ($X^2 = 28,61$, $p < 0,05$). O teste de Dunn, juntamente com os gráficos de *boxplot*, mostrou que essa diferença foi entre 2013 e 2015 e entre 2015 com 2018, que tiveram valores de 2.092, 1.689 e 2.026 mm, respectivamente. Os valores de Chuva foram decrescentes para as classes na ordem EBF, WB, WSV, UBL, PW, GL, SV, CL, MF e DBF, com máximas de 2792 (2013), 2453 (2013), 2182 (2011), 2120 (2018), 2098 (2011), 2091 (2009), 1983 (2013), 2074 (2018), 2016 (2013) e 1941 (2013), e mínimas de 2163 (2015), 1895 (2015), 1706 (2015), 1605 (2015), 1702 (2010), 1533 (2015), 1530 (2015), 1527 (2010), 1528 (2010) e 1475 (2010) mm. *Outliers* entre 2013 e 2015 acima dos valores máximos e abaixo dos mínimos foram vistos para a variável Chuva, sendo EBF a classe responsável pelos *outliers* acima (Fig 9f; Tabela 4).

Os valores de GPP foram decrescente das classes florestais para as classes mais antropizadas, na ordem EBF, WSV, DBF, MF, SV, GL, CL e PW, com as máximas de 55,43 (2018), 43,10 (2018), 39,20 (2018), 36,23 (2017), 36,00 (2019), 31,25 (2019), 24,03 (2018) e 0,73 (2014), e mínimas de 50,23 gC m^{-2} , em 2013, e 35,53, 22,90, 22,35, 23,53, 16,25, 16,88 e 0,43 gC m^{-2} , em 2016 (Fig. 4). As classes EBF, DBF e WSB apresentaram maiores valores de GPP no ano de 2018, mas em geral os valores máximos foram observados após 2017 enquanto os valores mínimos foram em 2016. Na classe EBF foi observada queda em GPP logo após os períodos de seca, de 53,59 gC m^{-2} , em 2010, para 52,89 e 52,99 gC m^{-2} , em 2011 e 2012, e de 58,07 gC m^{-2} , em 2015, para 55,35 gC m^{-2} , em 2016 (Fig. 9d; Tabela 4).

As classes EBF e WSV apresentaram menor CO₂Flux em 2014, de -3,55 e -0,98 $\mu\text{mol m}^{-2}\text{s}^{-1}$, enquanto DBF e MF foram de -0,28 (2018) e -0,53 (2009) $\mu\text{mol m}^{-2}\text{s}^{-1}$, respectivamente.

Outliers acima dos valores máximos foram vistos para todos os anos na variável CO₂Flux, na classe WB. As classes DBF e MF tiveram mínimos em 2013 e máximos em 2012 e 2010, respectivamente (Fig. 9e; Tabela 4).

Os anos de 2014 e 2018/19 apresentaram as maiores médias GPP de 24,26, 26,24 e 26,03 gC m⁻², respectivamente, e menor CO₂Flux. Além disso, os anos com valores mais baixos de precipitação, como 2010 e 2015/16 demonstraram essa dependência destes índices a fatores climáticos, com menores médias de GPP, de 22,76 (2015) e 19,24 (2016) gC m⁻², e CO₂Flux superior, de 2,80 (2010) μmol m⁻² s⁻¹ (Fig. 9d,e,f e Tabela 4).

A correlação entre as variáveis CO₂Flux e GPP foi forte e negativa, de -0,75, que também significou que o aumento de uma influência na diminuição de outra (KOZAK, 2009), e foi estatisticamente significativo para as classes CL e PW, de -0,65 e -0,69, respectivamente. Observou-se baixa correlação entre as variáveis CO₂Flux e GPP com Chuva e foi devido à não linearidade entre elas, observada pelo gráfico de dispersão na parte inferior do gráfico (Fig. 11).

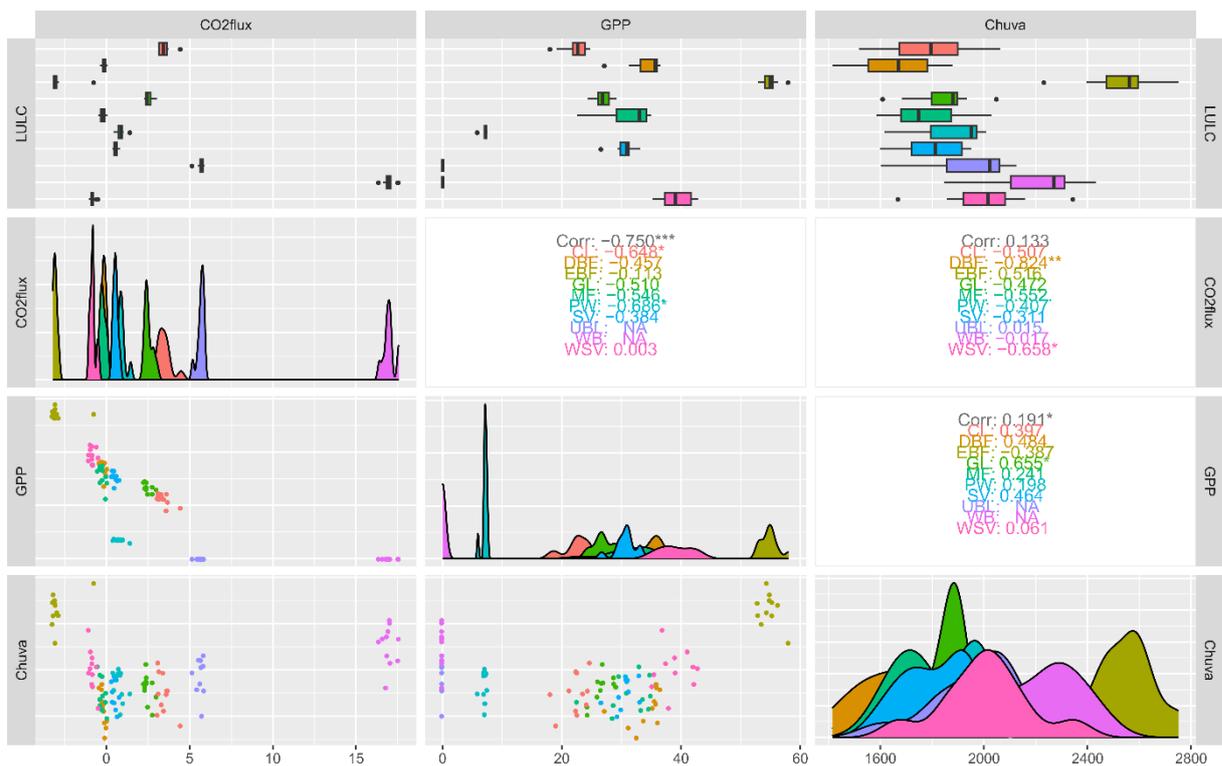


Figura 11 – Gráfico de dispersão da distribuição e as correlações entre as variáveis GPP, CO₂Flux e Chuva nos diferentes uso e cobertura do solo. Os valores mostrados em cinza indicam a correlação geral, enquanto os valores coloridos indicam a correlação entre os uso e cobertura do solo. *, ** e ***: significativos a 5, 1 e 0,1% de probabilidade pelo teste t, respectivamente.

Na correlação CO₂Flux com Chuva, as classes DBF e WSV tiveram uma forte correlação negativa, de -0,82 e -0,66, o que evidencia que o aumento nos valores de precipitação causa uma diminuição nos valores de CO₂Flux. Apenas EBF e UBL apresentaram correlação positiva, embora fraca, mostrando que o aumento nos valores de precipitação pode aumentar os

valores de CO_2Flux . Na correlação GPP com Chuva, apenas EBF apresentou correlação negativa, também fraca; observou-se correlação forte positiva para GL, de 0,66 (Fig. 11).

Os dois primeiros componentes principais (Dim1 e Dim2), que analisaram o cluster nas classes e variáveis, foram responsáveis por 58,4% e 35,4% da variância total entre os dados. Maior afinidade foi observada para GPP com EBF e com WSB e foi mais distante para WB e UBL. A variável CO_2Flux esteve mais associada a classe WB, ficando próximo também à UBL devido aos valores mais altos para esta variável. As demais classes com presença de vegetação variaram entre negativo e positivo ou foram próximas de zero, o que pode estar relacionado à pouca capacidade do índice CO_2Flux em caracterizar essas classes. Além disso, Chuva teve maior proximidade com as classes EBF e WB, pois foram as que tiveram precipitações acima de 2200 mm para todos os anos do período estudado (Fig. 12).

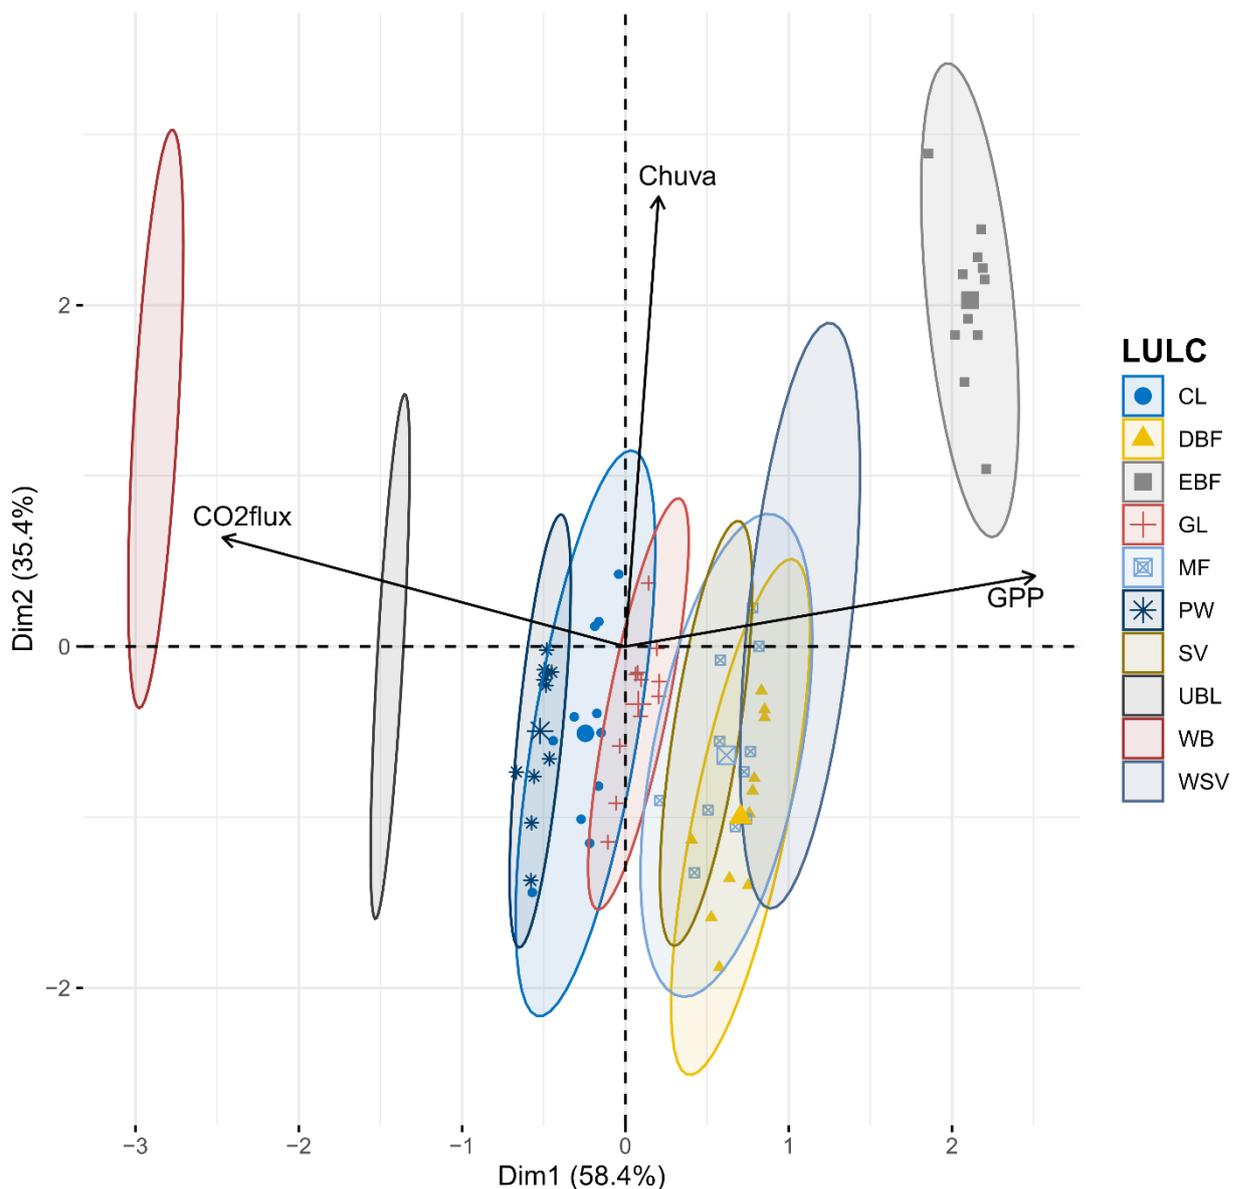


Figura 12 - Análise de componentes principais para as variáveis nos diferentes uso e cobertura do solo

Foi observada grande afinidade de GPP com EBF, isso porque esta classe teve os maiores valores de produção de biomassa, bem como também a classe WSV, em seguida, isso por que estas classes foram as maiores classes florestais da Amazônia Legal e de maior absorção e sumidouro de carbono (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Ainda foi mais distante de WB e UBL, porque estas classes não apresentaram absorção nenhuma em GPP (Fig. 9). Foi possível afirmar que GPP caracterizou classes de maiores absorções de carbono, bem como as que não absorveram carbono algum, e a PCA foi eficiente em demonstrar isso.

Com a finalidade de avaliar a existência de tendências monotônicas em séries históricas das três variáveis (GPP, CO₂Flux e Chuva) nas 10 classes de uso e cobertura da BLA (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL e WB), foi utilizado o teste de Mann-Kendall, que apresenta maior robustez quanto a desvios de normalidade e não-estacionaridade dos dados da série histórica em comparação com outros testes paramétricos (AHMAD *et al.*, 2022; CAÚLA *et al.*, 2017). A análise de tendência foi realizada observando-se o valor de Z, como recomendado por Mann (1945) e Kendall (1975). A identificação dos anos com tendência ao longo da série temporal (2009-2019) para cada variável foi realizada pelo Teste de Pettitt. Foram selecionados pontos em que as classes não foram alteradas ao longo dos anos, mas sofreram influência das mudanças nos usos de classes adjacentes (Tabela 5).

Tabela 5 – *p-value* para os testes de Mann-Kendall e Pettitt para as variáveis GPP, CO₂Flux e Chuva na BLA, agrupadas por uso e cobertura do solo.

Classes	GPP			CO ₂ Flux			Chuva		
	Mann-Kendall	Z	Pettitt	Mann-Kendall	Z	Pettitt	Mann-Kendall	Z	Pettitt
EBF	0,07*	1,80	0,04**	0,24	-1,18	0,56	0,56	0,58	0,79
DBF	0,58	0,55	0,42	0,64	-0,46	1,00	0,60	0,52	0,41
MF	0,44	0,77	0,01***	0,54	-0,61	0,80	0,76	0,30	0,13
WSV	0,29	1,06	0,28	0,92	0,10	1,00	0,21	-1,27	0,73
SV	0,94	0,07	1,00	0,28	-1,07	0,86	0,66	-0,43	1,00
GL	0,63	0,48	0,83	0,59	-0,54	1,00	0,19	-1,30	0,19
CL	0,22	1,22	0,10	0,39	-0,86	0,52	0,41	0,83	0,31
PW	0,74	-0,33	1,00	0,97	-0,04	1,00	0,34	-0,95	1,00
UBL	-	-	-	0,12	1,55	0,47	0,76	0,30	0,78
WB	-	-	-	0,76	-0,30	1,00	0,58	-0,56	0,65

*, ** e ***: significativos a 10, 5 e 1% de probabilidade pelo os testes de Mann-Kendall e Pettitt. Florestas perenes de folhas largas (EBF); Floresta decíduas de folhas largas (DBF); Florestas mistas (MF); Savanas lenhosas (WSV); Cerrados (SV); Campos (GL); Pântanos ou pantanal (PW); Cultivos agrícolas (CL); Cidades ou área urbana (UBL); Corpos d'água (WB).

Para a classe EBF, Mann-Kendall demonstrou um aumento de GPP ($p < 0,1$) e Pettitt atestou que foi após 2013 ($p < 0,05$) em que houve este aumento em relação a anos anteriores.

Para outras classes vegetativas, como MF ($p < 0,01$), esse aumento foi observado principalmente após 2016/17. Apesar de ser observada a mudança no uso e cobertura do solo, com diminuição de florestas e aumento de áreas antropizadas, em geral, não foram detectadas tendências significativas nos dados para as variáveis GPP, CO₂Flux e Chuva pelo teste de Mann-Kendall e Pettitt. No entanto, de acordo com o valor de Z, foi observada uma tendência positiva de GPP, principalmente para EBF, WSV e CL, e negativa de CO₂Flux, para EBF e SV, ao longo dos anos estudados. Também foi observada tendência negativa, ou diminuição, dos valores de Chuva ao longo dos anos, para WSV, SV, GL, PW e WB, que se localizam principalmente na região de maiores mudanças do uso e cobertura do solo, de classes florestais para outros usos, caracterizado por desmatamento (SILVA JUNIOR *et al.*, 2019a).

Com tais resultados, foi observada que as mudanças do uso e cobertura do solo afetam a dinâmica de C, analisada neste trabalho por GPP e CO₂Flux principalmente, e que as precipitações têm menor relação com essa dinâmica na série temporal de 2009 a 2019. No entanto, quando se considera os ciclos de eventos *El Niño* e *La Niña*, as precipitações são mais intensamente afetadas e, por consequência, a dinâmica de C também sofre forte variação, com significativas baixas de estoque e aumento de emissões no leste.

Estes resultados podem indicar o ponto de inflexão da BLA, na região do Arco do Desmatamento, em que o leste tende a emitir mais carbono, com pouca ou nenhuma absorção, caracterizando as principais conversões de florestas para áreas antropizadas, enquanto o oeste tende a estocar e capturar carbono.

5. DISCUSSÃO

5.1 O EFEITO DAS MUDANÇAS NO USO E COBERTURA DO SOLO EM TERRAS INDÍGENAS, ÁREAS PROTEGIDAS E OUTRAS ÁREAS IMPORTANTES DE CONSERVAÇÃO

A redução observada nas classes florestais EBF, WSV e SV foi de 67,28%, 4,38%, 16,24%, em 2009 para 65,96%, 4,38%, 15,51%, em 2019, respectivamente, enquanto áreas antropizadas, como GL e CL, foram incrementadas de 8,53% e 0,92%, em 2009, para 10,05% e 1,22%, em 2019, respectivamente, possivelmente caracterizando desmatamento (SILVA JUNIOR *et al.*, 2019a).

A classe floresta EBF foi observada no centro, oeste e norte da Amazônia Legal. Por ser a maior área de floresta da BLA, a classe EBF representa um grande e importante sumidouro de carbono (HUI *et al.*, 2015; IBGE, 2021; SILVA *et al.*, 2023). Essa classe também é conhecida como Floresta Ombrófila Densa ou Floresta Tropical Pluvial (RIBEIRO; WALTER, 2008), é a principal fitofisionomia do bioma amazônico, e ocorre em áreas tropicais ou equatoriais, onde as precipitações são distribuídas regularmente ao longo do ano (ALVARES *et al.*, 2013; COUTINHO, 2016; DUBREUIL *et al.*, 2018; RIBEIRO; WALTER, 2008). Esse tipo de floresta é preservado principalmente sobre TI e UC da região (BEGOTTI; PERES, 2019; CRISOSTOMO *et al.*, 2015; LIMA *et al.*, 2022; QIN *et al.*, 2023; SILVEIRA *et al.*, 2018).

As terras indígenas da Amazônia brasileira cobrem 27% da área com florestas, abrigam 173 etnias e são fundamentais para a reprodução física e sociocultural dos povos indígenas, além de serem áreas importantes para a conservação da biodiversidade regional e global (CRISOSTOMO *et al.*, 2015; QIN *et al.*, 2023). Além disso, as TI e UC estão em metade da área de floresta da BLA, desempenhando papéis importantes na conservação e biodiversidade e na mitigação do clima (BEGOTTI; PERES, 2019; QIN *et al.*, 2023; SILVEIRA *et al.*, 2018).

No Brasil, as taxas de desmatamento, e consequentes mudanças no uso e cobertura do solo, em áreas florestais protegidas por TI e UC foram até dez vezes menores que em áreas sem proteção ambiental. Isso porque essas áreas possuem maior cobertura florestal e menor pressão de desmatamento em comparação com as áreas sem proteção ambiental, que tendem ter alta pressão de desmatamento (QIN *et al.*, 2023).

Semelhante à classe EBF, o SV e o WSV, que representam as principais fitofisionomias do bioma Cerrado (COUTINHO, 2016; RIBEIRO; WALTER, 2008), juntas sofreram uma

redução de 68.186,11 km². O SV classe foi observado nos biomas Cerrado e Pantanal e em suas transições com o bioma Amazônico (IBGE, 2020; QIN *et al.*, 2023; SILVA JUNIOR *et al.*, 2019a), próximo às TI, UCs e rodovias, desde o norte, na TI Parque do Tumucumaque, no estado do Pará, entorno das rodovias BR-210 e BR-174 e nas TI São Marcos e Raposa Serra do Sol, em Roraima, e no Parque Estadual Serra do Aracá – AM. Na parte central, a classe SV foi observada nas rotas agrícolas de Mato Grosso, entorno da BR-163 até Santarém - PA e na BR-230, do estado do Maranhão até Lábrea – AM, enquanto ao sul, entorno da BR-364, até Mâncio Lima - AC (FUNAI, 2019; IBGE, 2020, 2021; LIMA *et al.*, 2022; WWF, 2023).

A classe WSV, também conhecida como cerrado típico (IBGE, 2019), foi observada no nordeste, desde o rio Amazonas até a sua foz no Oceano Pacífico, no Oiapoque – AM e no leste, nas proximidades da rodovia BR-230, no estado do Maranhão, até o rio Tapajós, no estado do Pará; e, ao sul, em todo o perímetro da rodovia BR-364, principalmente nos municípios de Comodoro, Sapezal e Campo Novo do Parecis – MT, alguns dos principais municípios produtores de soja no estado (ROSSI *et al.*, 2022), e também na TI Nambikwara (FUNAI, 2019; IBGE, 2021; WWF, 2023).

No gradiente de nordeste para sul da BLA, foram observadas grandes áreas das classes GL e CL, aparecendo próximas umas das outras, principalmente na região do “Arco do Desmatamento” (HERRERA; PFAFF; ROBALINO, 2019; PERES, 2023; QIN *et al.*, 2023), uma transição entre os biomas Cerrado e Amazônia (SILVA JUNIOR *et al.*, 2019a), que se estende do nordeste do estado do Pará ao leste do estado do Acre, representando a maior fronteira agrícola em expansão no mundo (HERRERA; PFAFF; ROBALINO, 2019; PERES, 2023; QIN *et al.*, 2023; WWF, 2023).

A classe GL apareceu principalmente no médio leste, onde estão localizados o Parque Estadual do Jalapão e a UC Estação Ecológica Serra Geral, no Tocantins, e UC Parque Nacional das Nascentes do Rio Parnaíba, no Maranhão (IBGE, 2020, 2021). Uma porção significativa foi observada a nordeste da ilha de Marajó e a norte de Roraima, ambas as regiões no norte da BLA. Outras áreas foram observadas na região central da Amazônia Legal, como nas TI Parque do Tumucumaque e Munduruku, Báu, Menkragnoti, Panará, Paresi e Parque do Xingu, em Pará e Mato Grosso (FUNAI, 2019; IBGE, 2021). Esta classe é frequentemente relacionada às pastagens, uma classe vegetativa de alta antropização (ALMEIDA *et al.*, 2018) e com alto risco de incêndio (AMARAL *et al.*, 2019; DA SILVA JUNIOR *et al.*, 2022; DA SILVA JÚNIOR *et al.*, 2019; ZHANG *et al.*, 2017b).

Como mostra o distrito de Santo Antônio do Matupi, a intensificação dos processos de mudança de uso e cobertura do solo ocorre em TI e UC, como o Parque Nacional dos Campos

Amazônicos, a Floresta Nacional do Aripuanã, a Área de Proteção Ambiental Campos de Manicoré e a Reserva Biológica de Manicoré, criada com o objetivo de proteger a diversidade biológica e controlar o processo de ocupação da região (BRASIL, 2016).

Além disso, o distrito de Santo Antônio do Matupi fica próximo às TI Diahui, Pirahã, Sepoti, Tenharim Marmelos e Tenharim do Igarapé Preto, as quais também são responsáveis pela preservação ambiental, ecológica e social (CRISOSTOMO *et al.*, 2015; QIN *et al.*, 2023). No entanto, esse distrito é conhecido por ser uma importante região de extração de madeira, e, portanto, um grande destruidor de florestas nativas. Esse fato foi confirmado quando foram observadas perdas de florestas primárias em Santo Antônio do Matupi, principalmente entre 2004 e 2018, quando 63,28% da área foi convertida em pastagens (DUARTE *et al.*, 2021).

Esses processos de intensificação foram induzidos pelo cenário político no Brasil, como resultado de mudanças significativas nas leis, políticas e regulamentações ambientais que favoreceram o desmatamento e a expansão da atividade agrícola em áreas próximas à floresta (AMIGO, 2020; CARDIL *et al.*, 2020; OLIVEIRA *et al.*, 2020; SCHIELEIN; BÖRNER, 2018). Adicionalmente, a conservação florestal em TIs/UCs tem enfrentado ameaças crescentes de leis e regulamentos ambientais enfraquecidos, mudanças nas políticas governamentais e desenvolvimento econômico maciço, como as mudanças nos usos nessas áreas (BEGOTTI; PERES, 2019; SILVEIRA *et al.*, 2018). Com isso, na BLA, a conversão de florestas em pastagens e terras agrícolas tiveram emissões relativamente altas, ultrapassando 340 Tg C ano⁻¹ em 2010 (FERREIRA BARBOSA *et al.*, 2021), porque provavelmente a seca desse ano influenciou essas emissões extremamente altas (ARAGÃO *et al.*, 2018).

Além disso, essas áreas com maior fragmentação das florestas e próximas a grandes estradas, áreas de pastagem, regiões de agricultura e cerrado são as áreas com maior risco de incêndio frequente (AMARAL *et al.*, 2019; DA SILVA JUNIOR *et al.*, 2022; DA SILVA JÚNIOR *et al.*, 2019; LOVEJOY; NOBRE, 2018, 2019; ZHANG *et al.*, 2017b). As florestas secundárias no noroeste crescem até 2x mais rápido ($3,0 \pm 1,0 \text{ Mg C}^{-1} \text{ ano}^{-1}$) em comparação com as regiões orientais ($1,3 \pm 0,3 \text{ Mg C ha}^{-1} \text{ ano}^{-1}$), o que poderia contribuir para a mitigação das alterações climáticas; no entanto, o impacto de perturbações como incêndios e desmatamentos repetidos antes da regeneração reduz a regeneração em 20% no oeste ($2,4 \pm 0,8 \text{ Mg C ha}^{-1} \text{ ano}^{-1}$) e em 55% no leste ($0,8 \pm 0,8 \text{ Mg C ha}^{-1} \text{ ano}^{-1}$) (HEINRICH *et al.*, 2021).

5.2 O FLUXO ESPACIAL DE CARBONO NA AMAZÔNIA LEGAL

Os maiores valores de GPP foram encontrados nas regiões norte, oeste e centro, coincidindo com as classes florestais, principalmente a classe EBF, e os valores máximos concordam com Zhang et al. (2017a), que observou um pico mais alto do GPP também próximo à linha do equador (ALMEIDA *et al.*, 2018; DA SILVA JUNIOR *et al.*, 2022).

Por outro lado, as classes EBF, MF, SV e WSV diminuíram em extensão, enquanto as classes GL, CL, UBL, PW e WB aumentaram, e com essas mudanças de uso e cobertura do solo, foi afetada toda a região pela diminuição do GPP, o que pode levar a uma exacerbação das mudanças climáticas (DE OLIVEIRA-JÚNIOR *et al.*, 2021), como a diminuição de chuvas visto durante a temporada 2015/16. Isto porque 2015/16 foi um ano de extrema seca por *El Niño* (NOAA, 2023), e estas mudanças agravaram as emissões devido a maiores perdas de carbono por desmatamento e incêndios florestais. Além disso, essas áreas que deixam de ser florestas também tendem a absorver e fixar menos carbono (DA SILVA JÚNIOR *et al.*, 2019; LOVEJOY; NOBRE, 2018, 2019). Assim, nesta área passa a haver deficiência na captura de carbono, com pouca ou nenhuma absorção e estocagem (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Semelhante aos achados neste trabalho, a absorção de carbono variou de 75,1 gC m⁻² ano⁻¹, na parte norte e central da BLA, e foram menores que 40 gC m⁻² ano⁻¹, na região de leste a sul (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005).

Os menores valores de CO₂Flux foram encontrados na região central e oeste da BLA, foram representados pelas classes florestais EBF, DBF, MF e WSV, com a classe EBF tendo o menor valor (ROSSI *et al.*, 2022), e os maiores valores foram observados nas regiões de fronteira do nordeste para o sul, onde foram verificadas as classes SV, GL, CL e PW (DELLA-SILVA *et al.*, 2022; ROSSI *et al.*, 2022). Portanto, pode-se verificar que as áreas de floresta que foram convertidas para outros usos resultaram em valores de CO₂Flux mais elevados, que caracterizam as fontes de CO₂, enquanto grandes áreas de florestas contínuas tendem a ter valores mais baixos e contribuem positivamente para o balanço de carbono como sumidouros, ajudando a mitigar os impactos das mudanças climáticas (DELLA-SILVA *et al.*, 2022; RAJU *et al.*, 2023; ROSSI *et al.*, 2022).

As menores precipitações foram observadas nas bordas leste-sul da área estudada e no estado de Roraima, áreas correspondentes ao bioma Cerrado (COUTINHO, 2016; IBGE, 2021) ou áreas de transição entre os biomas Amazônia-Cerrado (SILVA JUNIOR *et al.*, 2019a), assim como observado para as variáveis anteriores, com menor GPP e maior CO₂Flux, onde foram verificadas as classes SV, GL, CL e UBL. Este fato ocorreu devido ao regime climático do

bioma Cerrado, do tipo “Aw” (clima tropical, com inverno seco), na fronteira E-S da BLA, com períodos chuvosos e secos bem definidos (ALVARES *et al.*, 2013; DUBREUIL *et al.*, 2018).

A distribuição espacial dos *hotspots* de XCO₂ concentrou-se na região central e SE da BLA, onde foi observada a maioria das classes antrópicas, representadas por emissões de CO₂ mais altas em comparação com as florestas, e foi influenciada pelas mudanças climáticas, como a diminuição das chuvas (ALVES *et al.*, 2017; BERENGUER *et al.*, 2021; FERREIRA BARBOSA *et al.*, 2021; LIN *et al.*, 2017; STAAL *et al.*, 2020; WAGLE *et al.*, 2016) e mudanças no uso e cobertura do solo (SCHIELEIN; BÖRNER, 2018).

A maioria das regiões central, norte e oeste da BLA apresentou agrupamentos espaciais não significativos ou de *coldspots* a nível de 90% de confiança, demonstrando certo equilíbrio de XCO₂, regiões coincidentes com a classe EBF (principal classe florestal). Na Amazônia Oriental, foram encontrados *coldspots* espaciais com 90% de confiança, mais representativos em 2016 (SANTOS *et al.*, 2022). Os *hotspots* apresentaram valores menores em 2018 do que em outros anos, apresentando uma redução de 0,7% nas médias anuais de XCO₂, em relação a 2015 (ROSSI *et al.*, 2022).

Como esperado, os valores máximos de precipitação foram encontrados nas regiões do estado do Amapá, noroeste do Amazonas e nordeste do Pará, próximas à linha do equador, que possui clima tipo “Af”, caracterizado por altas temperaturas e estação chuvosa durante todo o ano (ALVARES *et al.*, 2013; DUBREUIL *et al.*, 2018). Estes valores explicam os achados para GPP, em que locais de maiores precipitações também apresentam maior absorção e armazenamento de carbono por área e vice-versa. Nestes lugares de alta precipitação, foram observados valores de GPP acima de 16 gC m⁻² dia⁻¹, enquanto para locais secos, o valor máximo observado foi de 12 gC m⁻² dia⁻¹ (CHAGAS *et al.*, 2019).

Os dados do CHIRPS se mostraram satisfatórios para a avaliação espaço-temporal da precipitação na BLA e representaram uma alternativa eficiente aos dados de estações meteorológicas (DE OLIVEIRA-JÚNIOR *et al.*, 2021). Especialmente, foi possível observar os danos causados nos anos de 2010 e 2015, em que houve redução das chuvas mais acentuada, principalmente em 2015 (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005), em que ocorreu uma diminuição significativa das chuvas no “arco do desmatamento” (HERRERA; PFAFF; ROBALINO, 2019; PERES, 2023; QIN *et al.*, 2023), aumentando as emissões de gases de efeito estufa nas classes mais antropizadas (FERREIRA BARBOSA *et al.*, 2021). Essa baixa precipitação foi observada no estado de Mato Grosso, seguido pelos estados de Rondônia e Acre, regiões sul e sudeste na Amazônia brasileira, com chuvas abaixo de 1.360 mm e, em casos extremos, esses valores foram inferiores a 520 mm (DA SILVA JUNIOR *et al.*, 2022;

ZHAO *et al.*, 2005). Isso provavelmente ocorreu devido ao maior número de incêndios observados em 2015 (FERREIRA BARBOSA *et al.*, 2021).

5.3 ANÁLISE DE CARBONO POR USO E COBERTURA DO SOLO

Os maiores valores de GPP ocorreram para as classes floresta, EBF, DBF, MF, WSV e SV ($> 31,32 \text{ gC m}^{-2}$), enquanto os menores ocorreram para as classes antropizadas, GL, PW, CL, UBL e WB ($< 25,71 \text{ gC m}^{-2}$). Semelhante aos achados neste trabalho, a absorção de carbono variou de 50 a $103 \text{ gC m}^{-2} \text{ ano}^{-1}$, com média de $75,1 \text{ gC m}^{-2} \text{ ano}^{-1}$, para classes florestais, e menores que $40 \text{ gC m}^{-2} \text{ ano}^{-1}$, para classes mais antropizadas, como lavoura, pastagens e fragmentos florestais (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Na transição entre floresta semidecídua (DBF e MF) e cerrado (WSV e SV), foram encontrados valores de GPP de $27,7 \text{ gC m}^{-2} \text{ ano}^{-1}$ (2003–2006) e de $25,2 \text{ gC m}^{-2} \text{ ano}^{-1}$, para pastagem (ALMEIDA *et al.*, 2018).

As classes GL, CL e UBL foram mais positivas para CO_2Flux ($> 2,83 \mu\text{mol m}^{-2} \text{ s}^{-1}$) e atuaram como as principais fontes de emissões de CO_2 nas mudanças de uso e cobertura do solo (ROSSI *et al.*, 2022), diminuindo a quantidade de carbono absorvido pelas florestas ao reduzir suas áreas através do desmatamento (SILVA JUNIOR *et al.*, 2021).

Rossi *et al.* (2021) relataram que pastagens (GL) e cultivos agrícolas (CL) obtiveram de 2,27 e $4,49 \mu\text{mol m}^{-2} \text{ s}^{-1}$, respectivamente, indicando emissão de carbono, perdendo apenas para áreas urbanas (UBL) e corpos d'água (WB). Os valores máximos de CO_2Flux foram observados para as regiões classificadas como WB, representando a menor absorção de carbono, com o maior valor para o ano de 2010, de $17,28 \mu\text{mol m}^{-2} \text{ s}^{-1}$ (ROSSI *et al.*, 2021). Um estudo realizado em 2017 no sul da Amazônia, as florestas (EBF) apresentaram valores próximos a $-7,18 \pm -2,92$ e solos descobertos (BN), $6,46 \pm 2,23 \mu\text{mol m}^{-2} \text{ s}^{-1}$, com valores intermediários para pastagem (GL) (DELLA-SILVA *et al.*, 2022).

Assim como GPP, a variável CO_2Flux , utilizada para medir a eficiência do processo de absorção de carbono relacionado à vegetação, demonstrou as diferenças entre as classes mais vegetadas quando comparadas às classes antropizadas (BOAS DOS SANTOS, 2017; ROSSI *et al.*, 2021). Pode-se observar que PW, UBL e WB foram as maiores fontes de carbono, com quase nenhuma absorção ao longo dos anos estudados. GL e CL tiveram as menores absorções de carbono em comparação com as outras classes vegetativas e ainda foram uma das que mais emitiram carbono, depois do grupo PW, UBL e WB, e por isso foram caracterizadas como as

principais classes de mudanças do uso do solo (ROSSI *et al.*, 2021). As classes DBF, MF, SV e WSV apresentaram maiores absorções de carbono e menores emissões de carbono, perdendo apenas para EBF, as quais poderiam ser agrupadas como fragmentos florestais, uma vez que estas se encontram distribuídas aleatoriamente na área estudada e estão quase sempre associadas a CL e GL.

As áreas vegetadas apresentaram valores menores ($< 1 \mu\text{mol m}^{-2} \text{s}^{-1}$), negativos para as classes tipicamente florestais, EBF e WSV ($< -0,65 \mu\text{mol m}^{-2} \text{s}^{-1}$), indicando a maior absorção de carbono (ROSSI *et al.*, 2021). Além disso, esses valores foram menores quanto mais afastados de corpos d'água, principalmente para EBF. Estudos destacaram um aumento substancial na fixação de carbono para áreas de EBF porque compreendem a maior parte da floresta amazônica (~ 65%) e para MF e WSV foram observados apenas valores ligeiramente inferiores em NPP (proporcional a GPP) (SILVA *et al.*, 2023).

Os valores máximos de precipitação foram observados para o ano de 2013, na classe EBF, e 2011 ou 2018, para áreas mais antropizadas, anos de anomalias negativas, e os mínimos foram para os anos de 2010 e 2015, para todas as classes, anos de anomalias positivas (NOAA, 2023). Apenas para a classe EBF, em 2013 o GPP diminuiu devido à disponibilidade reduzida de radiação de ondas curtas devido à cobertura de nuvens (DUBREUIL *et al.*, 2018; RAJU *et al.*, 2023; WAGNER *et al.*, 2017). Para a variável CO₂Flux, EBF apresentou o menor valor em 2010 e o maior em 2013, enquanto DBF e MF tiveram mínimas em 2013 e máximas em 2012 e 2010, respectivamente. De forma geral, os maiores valores foram observados em 2010 e/ou 2015, indicando emissão de carbono (ROSSI *et al.*, 2022).

Em suma, o menor valor de CO₂Flux e os maiores valores das variáveis GPP e Chuva foram observados para a classe EBF. As classes DBF, MF, WSV, SV e PW ficaram próximas de zero, para CO₂Flux, enquanto GL, CL e UBL ficaram entre 2 e 6 $\mu\text{mol m}^{-2} \text{s}^{-1}$. Para GPP, a maioria das classes ficaram entorno de 20 e 42 gC m^{-2} e as classes UBL e WB foram nulas para GPP por não representarem vegetação. Os maiores valores de precipitações coincidiram com as áreas classificadas como florestas (ZHANG *et al.*, 2021a), enquanto as menores, em áreas antropizadas (SCHIELEIN; BÖRNER, 2018) e com fitofisionomias de Cerrado (RIBEIRO; WALTER, 2008). Em áreas de florestas, observou-se maiores valores de GPP e Chuva, acima de 40,5 $\text{gC m}^{-2}\text{ano}^{-1}$ e de 2000 mm ano^{-1} , e menores valores de XCO₂ e CO₂Flux, abaixo de 400 ppm e -0,5 $\mu\text{mol m}^{-2}\text{s}^{-1}$, respectivamente.

A classe EBF, a maior classe florestal da BLA, absorveu uma média de 176,63 TgC ano^{-1} ; porém, no período avaliado, foi observada uma perda de 66.452,69 km^2 , deixando de absorver e armazenar 3,52 Tg C. Além disso, as classes florestais EBF, MF, WSV e SV juntas

absorveram uma média de 211,05 TgC ano⁻¹ e sofreram perdas de 135.922,34 km² na área entre 2009 e 2019, o que significou que 5,82 Tg C a menos foram absorvidos no período estudado devido a mudanças no uso e cobertura do solo. As classes GL e CL, principais conversões de uso do solo, absorveram 12,63 Tg C ano⁻¹. Essas classes aumentaram em 85.355,24 e 14.985,15 840 km², absorvendo 2,19 e 0,32 Tg C, o que correspondeu a 1,32 e 3,19 Tg C a menos que a classe EBF nessas áreas aumentadas, respectivamente, e emitiu $\pm 2x$ mais (2,83 e 3,50 $\mu\text{mol m}^{-2}\text{s}^{-1}$) do que EBF sozinha absorveu e armazenou. Tais resultados evidenciam que o BLA tem sofrido mudanças no uso e cobertura do solo, o que representa um aumento nas emissões de GEE, que contribuem para o aquecimento global (DA SILVA JUNIOR et al., 2022; FARIA et al., 2018b; LIMA et al., 2022).

Na classe EBF, observou-se uma queda em GPP logo após os períodos de seca, de 53,59 gC m⁻², em 2010, para 52,89 e 52,99 gC m⁻², em 2011 e 2012, e de 58,07 gC m⁻², em 2015, para 55,35 gC m⁻², em 2016. Para o EBF, a correlação mostrou que o aumento nos valores de Chuva pode aumentar os valores de CO₂Flux e diminuir os valores de GPP. Oliveira et al. (2021) relataram que, após três anos de queimada, houve distúrbios na relação de carbono e na sazonalidade das regiões florestais em comparação com os três anos anteriores; a floresta queimada apresentou então um GPP mais alto, devido a rebrota. Neste sentido, para os anos mais secos na BLA, verifica-se um aumento dos valores de GPP, como visto para 2015/16 principalmente (DA SILVA JUNIOR et al., 2022; ZHAO et al., 2005). No entanto, este trabalho não abordou a relação entre os incêndios ocorridos ao longo dos anos.

Além disso, chuvas abaixo da média entre 2012 e 2018, exceto 2013, limitaram significativamente o crescimento da vegetação, reduzindo a absorção fotossintética de CO₂ da atmosfera e levou à redução do GPP e aumento de CO₂Flux (RAJU et al., 2023; SILVA et al., 2023). O aumento das chuvas, como em 2013 e 2017/18, melhorou estes índices nos anos posteriores (RAJU et al., 2023), como observado em 2014 e 2018/19, que ocorreu para as demais classes de vegetação. Estudos recentes mostram que as mudanças climáticas intensificam a estação seca, gerando estresse no ecossistema, especialmente na Amazônia Oriental, região com os maiores índices de desmatamento (SILVA et al., 2023).

A correlação entre as variáveis CO₂Flux e GPP e Chuva foi fraca. Estudos explicam que a precipitação tem pouca influência na produção de folha, de apenas 29,6%, e que o principal fator climático para essa produção é a insolação (70,4%), o que pode ser constatado neste trabalho (WAGNER et al., 2017). Condições típicas de seca do tipo *El Niño* 3.4 foram observadas no leste da Amazônia, enquanto no oeste da Amazônia houve um alagamento incomum, principalmente em 2015/16, e esse dipolo úmido e seco é atribuído à localização do

aquecimento máximo da superfície do mar no Oceano Pacífico equatorial central (JIMÉNEZ-MUÑOZ *et al.*, 2016).

Neste sentido, a ausência de limitação da água, a produção foliar segue a insolação solar, enquanto em regiões com água limitada, as árvores produzem rapidamente folhas com as primeiras chuvas a se beneficiarem de alta insolação no final da estação seca (WAGNER *et al.*, 2017). Com isso, o aumento da insolação impulsiona o crescimento das folhas na ausência de limitação da água, como ocorre para essas florestas não limitadas pela água, mesmo com a ocorrência de *El Niño*, mas pode restringir esta produção na presença de *La Niña*, devido a menor radiação (ARAGÃO *et al.*, 2018). Essas florestas, cujos processos de dosséis são observados usando sensoriamento remoto, não são limitadas pela água e satisfazem suas demandas de água durante a estação seca, usando o suprimento de água subterrânea redistribuída da estação chuvosa (WAGNER *et al.*, 2017).

Assim, nas florestas equatoriais, a produção de biomassa se correlaciona com o aumento da disponibilidade de luz e a radiação fotossinteticamente ativa durante a estação seca e é impulsionado por uma alteração na insolação diária. No entanto, a disponibilidade de água restringe a fenologia foliar no sul da Amazônia, impedindo a manutenção do estado sempre-verde durante a estação seca e o esverdeamento se associa a um aumento na precipitação, sendo prejudicado por ocorrências de *El Niño* (WAGNER *et al.*, 2017). Em outro estudo, foram identificados também eventos extremos tanto em períodos chuvosos quanto em períodos de seca para a região *El Niño* 3.4, e foram associados às fases do ENOS (*El Niño*, *La Niña* e Neutro) (COSTA *et al.*, 2021), assemelhando-se com os resultados climáticos observados neste trabalho.

É relatado que a variabilidade temporal do CO₂Flux está correlacionada positivamente com a precipitação (ROSSI *et al.*, 2022), o que está de acordo com os nossos achados em relação à classe EBF; no entanto, a correlação foi negativa para a maioria das classes. Ainda, foi observado um aumento de NPP na Floresta Amazônica, atestando que EBF estabelecerá maior fixação de carbono em cenários futuros, enquanto as classes MF, CS e WSV apresentarão níveis mais baixos (SILVA *et al.*, 2023).

A soma destes dois primeiros componentes na análise PCA explicou 93,8% da variação total dos dados, considerada adequada para responder as relações das variáveis analisadas (REGAZZI; CRUZ, 2020), permitindo identificar os componentes que podem auxiliar na caracterização de uso e cobertura do solo da BLA, derivados dos dados de sensoriamento remoto (CAMARRETTA *et al.*, 2021). Foi observada uma grande afinidade de GPP com EBF, isso porque esta classe teve os maiores valores de produção de biomassa pelos valores de GPP,

isso por que esta classe foi a maior classe florestal da BLA e com a maior absorção e sumidouro de carbono por CO₂Flux (DA SILVA JUNIOR *et al.*, 2022; ZHAO *et al.*, 2005). Entretanto, o GPP ficou mais distante de WB e UBL, porque estas classes não apresentaram absorção em GPP (SILVA *et al.*, 2023). Foi possível observar que GPP caracterizou classes com maior absorção de carbono, bem como as que não absorveram nenhum carbono, e a análise de componentes principais foi eficiente em demonstrar isso.

Pode-se observar que a variável CO₂Flux esteve mais associada às classes WB e UBL, pois estas classes tiveram os maiores e mais positivos valores, e esta variável foi a que mais se distanciou para EBF, classe que teve os menores valores em todos os anos. Isso mostra que a variável CO₂Flux foi eficiente em caracterizar a relação de carbono com as classes WB e UBL sem vegetação, que indicaram maior emissão de CO₂ (ROSSI *et al.*, 2022). Esta variável também foi eficiente em caracterizar EBF como sumidouro (DELLA-SILVA *et al.*, 2022).

Apesar das mudanças no uso e cobertura do solo, com diminuição das florestas e aumento das áreas antropizadas, em geral, não foram detectadas tendências significativas nos dados para as variáveis GPP, CO₂Flux e Chuva. O teste de Pettitt permitiu confirmar a estacionariedade da série histórica, ou seja, as observações foram invariantes com relação à cronologia de suas ocorrências (PETTITT, 1979). Neste teste, o *p-value* foi menor que 0,05 apenas as classes EBF e MF, em que foram observados aumento nos valores de GPP, após 2013 e 2017, respectivamente, anos de influência de *La Niña* (NOAA, 2023). Além disso, o teste de Pettitt alegou ter um possível aumento de GPP para as classes florestais ao longo dos anos, ou seja, aumento da captura de CO₂ (ALMEIDA *et al.*, 2018; CHAGAS *et al.*, 2019; ZHANG *et al.*, 2021b). Estudos indicaram que haverá expansão de fixação de carbono na porção oeste da BLA (> 1.500 gC m⁻²). Em contrapartida, haverá uma intensificação das emissões de carbono nas áreas ao sul (< 710 gC m⁻²) (SILVA *et al.*, 2023), em sentido com o fundado neste trabalho.

A análise de anomalias nos valores de GPP e CO₂Flux determinou o impacto das mudanças nas emissões e absorção de CO₂ ocorridas na região (DA SILVA JUNIOR *et al.*, 2022) e, portanto, foi importante estimar suas variações temporais e espaciais para entender as respostas do carbono às mudanças climáticas e do uso e cobertura do solo (LIN *et al.*, 2017; WAGLE *et al.*, 2016).

Apesar das evidências que as classes florestais tenham aumentado a absorção e estoque de carbono ao longo dos anos, observou-se uma mudança nas precipitações, com possíveis diminuições de chuvas para a região do “arco do desmatamento” (HERRERA; PFAFF; ROBALINO, 2019; PERES, 2023; QIN *et al.*, 2023), onde se encontra a maior parte das mudanças de usos do solo, principalmente de classes florestais para outros usos (ROSSI *et al.*,

2022). Pode-se dizer que não foi observada evidência suficiente de que as por mudança no uso e cobertura das áreas adjacentes tenham sido responsáveis por modificar o fluxo de carbono nas classes analisadas no período estudado, ao contrário do que tem sido relatado (LOVEJOY; NOBRE, 2018, 2019).

Ainda, foram observadas tendências negativas, ou seja, diminuição dos valores de Chuva ao longo dos anos, para WSV, SV, GL, PW e WB, que se localizam principalmente na região de maiores mudanças do uso e cobertura do solo, de classes florestais para outros usos, caracterizado por desmatamento (SILVA JUNIOR *et al.*, 2019a). Estudos recentes mostram que as mudanças climáticas intensificam a estação seca, produzindo estresse no ecossistema, principalmente na Amazônia Oriental, região com os maiores índices de desmatamento, com forte presença de diferentes tipos de lavouras (SILVA *et al.*, 2023).

Embora não tenham sido observadas tendências pela análise estatística de aumento das emissões induzidas pelo uso e cobertura a partir de dados remotamente sensoriados na BLA, as concentrações de dióxido de carbono foram crescentes ao longo da série temporal, com aumento anual de 2,2 a 2,8 ppm. *Hotspots* também foram observados nas bordas leste a sul da área, especialmente para classes mais antropizadas, e *coldspots*, no centro da BLA, para floresta (ROSSI *et al.*, 2022). As classes não florestais representaram as maiores perdas de carbono, dada a menor capacidade de processamento de dióxido de carbono via fotossíntese nesses ecossistemas (DELLA-SILVA *et al.*, 2022).

A comparação do fluxo de CO₂ nas mudanças de uso e cobertura do solo na Amazônia Legal brasileira pelos índices GPP e CO₂Flux é a inovação deste trabalho. Também ganha destaque por associar a concentração atmosférica de CO₂ por meio de *hotspots* e precipitação ao longo dos anos, o que permitiu a verificação de tendências nos fluxos de carbono para a Amazônia Legal durante o período de 2009 a 2019.

6. CONCLUSÕES

O estudo atual fornece uma fonte de informações sobre as relações de uso e cobertura do solo e fluxos de carbono, especialmente para entender e promover ecossistemas mais sustentáveis na Amazônia Legal Brasileira. Porém, nossos resultados sugerem que houve mudanças nas florestas nativas em direção a ecossistemas mais antropizados, como pastagens, lavouras e fragmentos florestais, de leste a sul da BLA, principalmente próximas às terras indígenas e unidades de conservação, no “Arco do Desmatamento”.

A variação espacial e temporal das interações de carbono entre a atmosfera e a biosfera foi observada de acordo com as características climáticas e uso e cobertura do solo. As emissões de CO₂ aumentaram entre 2,2 e 2,8 ppm anualmente, com *hotspots* observados principalmente para a região SE da BLA, enquanto a captura de CO₂ por GPP e CO₂Flux apresentou aumento ao longo dos anos, principalmente após 2013, para florestas no norte e oeste, e 2016/17, para outras classes vegetativas no leste e sul da região.

A floresta absorveu 211,05 Tg C anualmente, mas perdeu 135.922,34 km² de área, o que significou 5,82 Tg C a menos de carbono absorvido devido à sua conversão para outros tipos de uso e cobertura do solo, enquanto a pastagem e a agricultura, as principais conversões, aumentam 100.340,39 km² e absorveram 1,32 e 3,19 gC a menos que EBF, e emitiu $\pm 2x$ mais do que EBF sozinho absorveu e armazenou.

Estes resultados podem indicar um ponto de inflexão da BLA, na região do Arco do Desmatamento, em que o E tende a emitir mais carbono, com pouca ou nenhuma absorção, caracterizando as principais conversões de florestas para áreas antropizadas, enquanto o oeste tende a estocar e capturar carbono.

É importante compreender a dinâmica climática e mudanças no uso e cobertura do solo que ocorrem em um dos principais responsáveis por estoques de carbono no mundo, a Amazônia, o que é fundamental para o cumprimento dos acordos internacionais assinados pelo Brasil para reduzir as emissões de CO₂ e para a conservação da biodiversidade, manutenção e recuperação dos estoques de carbono e outros serviços ecossistêmicos.

7. CONSIDERAÇÕES FINAIS E PERSPECTIVAS FUTURAS

Os resultados demonstraram perspectivas de aumento de produção de biomassa e captura do carbono na região norte e leste da Amazônia. No entanto, há grande mudança de uso e cobertura do solo que desfavorecem este equilíbrio, principalmente as conversões para pastagem (por vezes degradada) e agricultura que produzem pouca quantidade de biomassa e acarretam emissões de CO₂ para a atmosfera. Sabe-se que estas conversões foram necessárias para a produção de alimento e manutenção da vida humana e por isso é sugerido que haja um novo olhar para estas áreas convertidas de forma a garantir uma produção de alimento mais sustentável.

Para melhorar as estimativas e reduzir as incertezas na distribuição espaço-temporal do comportamento do carbono em áreas de mudança de uso e cobertura do solo, é necessário realizar mais estudos com dados de campo. Também é fortemente recomendável a análise de uma série temporal em um período mais longo para verificação de possíveis anomalias ou tendências.

Este trabalho sugere que os ciclos de *El Niño* podem favorecer a floresta Amazônica por permitir maior radiação solar em relação a *La Niña*, com aumento da captura de C e maior produção de biomassa. No entanto, para a área do “Arco do Desmatamento” isto se inverte, e os ciclos *El Niño* podem aumentar os processos de desmatamento e incêndios, momentos em que as áreas antropizadas necessitam de maior cuidado para não afetar áreas nativas e em reflorestamento e aceleram os aumentos de emissão de CO₂ para a atmosfera.

Neste sentido, estudos como este são importantes para atualização e implementação de políticas públicas, subsidiando uma alocação mais estratégica de recursos para a restauração florestal e proteção de terras indígenas e unidades de conservação, principalmente em áreas próximas das conversões de usos e cobertura do solo.

Futuramente, espera-se que os dados de sensoriamento remoto possam ser correlacionados com torres de fluxo de carbono na Amazônia Legal brasileira para obter resultados mais assertivos e complementar com mais robustez os achados apresentados neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAMI, M.; FREITAS, R. M. de; PADOVANI, C. R.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Estudo da dinâmica espaço-temporal do bioma Pantanal por meio de imagens MODIS. **Pesquisa Agropecuária Brasileira**, v. 43, n. 10, p. 1371–1378, out. 2008. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2008001000016&lng=pt&tlng=pt>.

AHMAD, S.; ISRAR, M.; AHMED, R.; ASHRAF, A.; AMIN, M.; AHMAD, N. Land use and cover changes in the Northern mountains of Pakistan; A spatio-temporal change using MODIS (MCD12Q1) Time Series. **Sarhad Journal of Agriculture**, v. 38, n. 4, p. 1419-1429, 2022. Disponível em: <<http://researcherslinks.com/current-issues/Land-use-and-Cover-Changes-Northern-Mountains-Pakistan-A-Spatio-Temporal-Change-using-MODIS/14/1/5409/html>>.

AL BALASMEH, O. I.; KARMAKER, T. Effect of temperature and precipitation on the vegetation dynamics of high and moderate altitude natural forests in India. **Journal of the Indian Society of Remote Sensing**, v. 48, n. 1, p. 121–144, 5 jan. 2020.

ALMEIDA, C. T. de; DELGADO, R. C.; GALVÃO, L. S.; ARAGÃO, L. E. de O. C. e; RAMOS, M. C. Improvements of the MODIS gross primary productivity model based on a comprehensive uncertainty assessment over the Brazilian Amazonia. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 268–283, nov. 2018.

ALSHARI, E. A.; GAWALI, B. W. Development of classification system for LULC using remote sensing and GIS. **Global Transitions Proceedings**, v. 2, n. 1, p. 8–17, jun. 2021.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ALVES, L. M.; MARENGO, J. A.; FU, R.; BOMBARDI, R. J.; ALVES, L. M.; MARENGO, J. A.; FU, R.; BOMBARDI, R. J. Sensitivity of Amazon regional climate to deforestation. **American Journal of Climate Change**, v. 6, n. 1, p. 75–98, 7 fev. 2017. Disponível em: <<http://www.scirp.org/journal/PaperInformation.aspx?PaperID=74585>>. Acesso em: 13 set. 2021.

AMARAL, S. S.; COSTA, M. A. M.; SOARES NETO, T. G.; COSTA, M. P.; DIAS, F. F.; ANSELMO, E.; SANTOS, J. C. dos; CARVALHO, J. A. de. CO₂, CO, hydrocarbon gases and PM_{2.5} emissions on dry season by deforestation fires in the Brazilian Amazonia. **Environmental Pollution**, v. 249, p. 311–320, 1 jun. 2019. . Acesso em: 13 set. 2021.

AMIGO, I. When will the Amazon hit a tipping point? **Nature**, v. 578, n. 7796, p. 505–507, 1 fev. 2020. . Acesso em: 14 set. 2021.

ARAGÃO, L. E. O. C.; ANDERSON, L. O.; FONSECA, M. G.; ROSAN, T. M.; VEDOVATO, L. B.; WAGNER, F. H.; SILVA, C. V. J.; SILVA JUNIOR, C. H. L.; ARAI, E.; AGUIAR, A. P.; BARLOW, J.; BERENQUER, E.; DEETER, M. N.; DOMINGUES, L. G.; GATTI, L.; GLOOR, M.; MALHI, Y.; MARENGO, J. A.; MILLER, J. B.; PHILLIPS, O. L.; SAATCHI, S. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, v. 9, n. 1, p. 536, 1 dez. 2018. Acesso em: 14 set. 2021.

ARAGÃO, L. E. O. C.; POULTER, B.; BARLOW, J. B.; ANDERSON, L. O.; MALHI, Y.; SAATCHI, S.; PHILLIPS, O. L.; GLOOR, E. Environmental change and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913–931, 1 nov. 2014. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/brv.12088>>. Acesso em: 13 set. 2021.

ARIMA, E. Y.; BARRETO, P.; ARAÚJO, E.; SOARES-FILHO, B. Public policies can reduce tropical deforestation: Lessons and challenges from Brazil. **Land Use Policy**, v. 41, p. 465–473, 1 nov. 2014. Acesso em: 14 set. 2021.

BAKER, T. R.; PHILLIPS, O. L.; MALHI, Y.; ALMEIDA, S.; ARROYO, L.; DI FIORE, A.; ERWIN, T.; HIGUCHI, N.; KILLEEN, T. J.; LAURANCE, S. G.; LAURANCE, W. F.; LEWIS, S. L.; MONTEAGUDO, A.; NEILL, D. A.; NÚÑEZ VARGAS, P.; PITMAN, N. C. A.; SILVA, J. N. M.; VÁSQUEZ MARTÍNEZ, R. Increasing biomass in Amazonian forest plots. **Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences**, v. 359, n. 1443, p. 353–365, 29 mar. 2004.

BARLOW, J.; BERENQUER, E.; CARMENITA, R.; FRANÇA, F. Clarifying Amazonia's burning crisis. **Global Change Biology**, v. 26, n. 2, p. 319–321, 1 fev. 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/gcb.14872>>. Acesso em: 13 set. 2021.

BARLOW, J.; LENNOX, G. D.; FERREIRA, J.; BERENQUER, E.; LEES, A. C.; NALLY, R. Mac; THOMSON, J. R.; FERRAZ, S. F. de B.; LOUZADA, J.; OLIVEIRA, V. H. F.; PARRY,

L.; RIBEIRO DE CASTRO SOLAR, R.; VIEIRA, I. C. G.; ARAGÃO, L. E. O. C.; BEGOTTI, R. A.; BRAGA, R. F.; CARDOSO, T. M.; DE OLIVEIRA, R. C.; SOUZA JR, C. M.; MOURA, N. G.; NUNES, S. S.; SIQUEIRA, J. V.; PARDINI, R.; SILVEIRA, J. M.; VAZ-DE-MELLO, F. Z.; VEIGA, R. C. S.; VENTURIERI, A.; GARDNER, T. A. Anthropogenic disturbance in tropical forests can double biodiversity loss from deforestation. **Nature**, v. 535, n. 7610, p. 144–147, 29 jun. 2016. Disponível em: <<https://www.nature.com/articles/nature18326>>. Acesso em: 14 set. 2021.

BARNES, M. L.; BRESHEARS, D. D.; LAW, D. J.; VAN LEEUWEN, W. J. D.; MONSON, R. K.; FOJTIK, A. C.; BARRON-GAFFORD, G. A.; MOORE, D. J. P. Beyond greenness: Detecting temporal changes in photosynthetic capacity with hyperspectral reflectance data. **PLOS ONE**, v. 12, n. 12, p. 1–17, 2017.

BEDIA, J.; HERRERA, S.; GUTIÉRREZ, J. M.; BENALI, A.; BRANDS, S.; MOTA, B.; MORENO, J. M. Global patterns in the sensitivity of burned area to fire-weather: Implications for climate change. **Agricultural and Forest Meteorology**, v. 214–215, p. 369–379, dez. 2015. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168192315007078>>.

BEGOTTI, R. A.; PERES, C. A. Brazil's indigenous lands under threat. **Science**, v. 363, n. 6427, p. 592–592, 8 fev. 2019.

BERENGUER, E.; LENNOX, G. D.; FERREIRA, J.; MALHI, Y.; ARAGÃO, L. E. O. C.; BARRETO, J. R.; DEL BON ESPÍRITO-SANTO, F.; FIGUEIREDO, A. E. S.; FRANÇA, F.; GARDNER, T. A.; JOLY, C. A.; PALMEIRA, A. F.; QUESADA, C. A.; ROSSI, L. C.; DE SEIXAS, M. M. M.; SMITH, C. C.; WITHEY, K.; BARLOW, J. Tracking the impacts of El Niño drought and fire in human-modified Amazonian forests. **Proceedings of the National Academy of Sciences of the United States of America**, v. 118, n. 30, e2019377118, 27 jul. 2021. Acesso em: 23 ago. 2022.

BOAS DOS SANTOS, C. V. **Modelagem espectral para determinação de fluxo de CO₂ em áreas de Caatinga preservada e em regeneração**. 2017. Universidade Estadual de Feira de Santana., Feira de Santana, 2017.

BP. **Statistical Review of World Energy**. Disponível em: <<https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html>>. Acesso em: 3 abr. 2022.

BRASIL. **Base Legislação da Presidência da República - Lei Complementar nº 124 de 03 de janeiro de 2007.** Disponível em: <<https://legislacao.presidencia.gov.br/atos/?tipo=LCP&numero=124&ano=2007&ato=ce1k3YU1ENRpWT819>>. Acesso em: 23 set. 2021.

BRASIL. **Decreto s/n, de 11 de maio de 2016. Área de Proteção Ambiental dos Campos de Manicoré.** Disponível em: <<https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/amazonia/lista-de-ucs/apa-dos-campos-de-manicore>>.

BROWN, C. F.; BRUMBY, S. P.; GUZDER-WILLIAMS, B.; BIRCH, T.; HYDE, S. B.; MAZZARIELLO, J.; CZERWINSKI, W.; PASQUARELLA, V. J.; HAERTEL, R.; ILYUSHCHENKO, S.; SCHWEHR, K.; WEISSE, M.; STOLLE, F.; HANSON, C.; GUINAN, O.; MOORE, R.; TAIT, A. M. Dynamic world, near real-time global 10 m land use land cover mapping. **Nature**, v. 9, n. 251, 2022.

BUCAŁA, A. The impact of human activities on land use and land cover changes and environmental processes in the Gorce Mountains (Western Polish Carpathians) in the past 50 years. **Journal of Environmental Management**, v. 138, p. 4–14, 1 jun. 2014.

BULLOCK, E. L.; WOODCOCK, C. E.; SOUZA, C.; OLOFSSON, P. Satellite-based estimates reveal widespread forest degradation in the Amazon. **Global Change Biology**, v. 26, n. 5, p. 2956–2969, 1 mai. 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/gcb.15029>>. Acesso em: 13 set. 2021.

CAMARRETTA, N.; EHBRECHT, M.; SEIDEL, D.; WENZEL, A.; ZUHDI, M.; MERK, M. S.; SCHLUND, M.; ERASMI, S.; KNOHL, A. Using airborne laser scanning to characterize land-use systems in a tropical landscape based on vegetation structural metrics. **Remote Sensing**, v. 13, n. 23, 4794, 26 nov. 2021.

CARDIL, A.; DE-MIGUEL, S.; SILVA, C. A.; REICH, P. B.; CALKIN, D.; BRANCALION, P. H. S.; VIBRANS, A. C.; GAMARRA, J. G. P.; ZHOU, M.; PIJANOWSKI, B. C.; HUI, C.; CROWTHER, T. W.; HÉRAULT, B.; PIOTTO, D.; SALAS-ELJATIB, C.; BROADBENT, E. N.; ZAMBRANO, A. M. A.; PICARD, N.; ARAGÃO, L. E. O. C.; BASTIN, J.-F.; ROUTH, D.; HOOGEN, J. van den; PERI, P. L.; LIANG, J. Recent deforestation drove the spike in Amazonian fires. **Environmental Research Letters**, v. 15, n. 12, 121003, 11 dez. 2020.

Disponível em: <<https://iopscience.iop.org/article/10.1088/1748-9326/abcac7>>. Acesso em: 14 set. 2021.

CARVALHO, J. L. N.; AVANZI, J. C.; SILVA, M. L. N.; MELLO, C. R. de; CERRI, C. E. P. Potencial de sequestro de carbono em diferentes biomas do Brasil. **Revista Brasileira de Ciência do Solo**, v. 34, n. 2, p. 277–290, abr. 2010. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-06832010000200001&lng=pt&tlng=pt>.

CAÚLA, R. H.; DE OLIVEIRA-JÚNIOR, J. F.; DE GOIS, G.; DELGADO, R. C.; PIMENTEL, L. C. G.; TEODORO, P. E. Nonparametric statistics applied to fire foci obtained by meteorological satellites and their relationship to the MCD12Q1 product in the state of Rio de Janeiro, Southeast Brazil. **Land Degradation and Development**, v. 28, n. 3, p. 1056–1067, 2017.

CHAGAS, M. C.; DELGADO, R. C.; DE SOUZA, L. P.; DE CARVALHO, D. C.; PEREIRA, M. G.; TEODORO, P. E.; SILVA JUNIOR, C. A. Gross primary productivity in areas of different land cover in the western Brazilian Amazon. **Remote Sensing Applications: Society and Environment**, v. 16, 100259, nov. 2019.

CHEN, Y.; WANG, X.; XIE, Z. Land cover diversity: Reshaping the socioeconomic value of land. **Journal of Environmental Management**, v. 332, 117404, abr. 2023.

COSTA, M. da S.; OLIVEIRA-JÚNIOR, J. F. de; SANTOS, P. J. dos; CORREIA FILHO, W. L. F.; GOIS, G. de; BLANCO, C. J. C.; TEODORO, P. E.; SILVA JUNIOR, C. A. da; SANTIAGO, D. de B.; SOUZA, E. de O.; JARDIM, A. M. da R. F. Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño–Southern Oscillation. **International Journal of Climatology**, v. 41, n. S1, p. E2111–E2135, 1 jan. 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/joc.6835>>. Acesso em: 26 jun. 2023.

COUTINHO, L. M. **Biomas brasileiros**. São Paulo: Oficina de Textos, 2016.

CRISOSTOMO, A. C.; ALENCAR, A.; MESQUITA, I.; SILVA, I. C.; DOURADO, M. F.; MOUTINHO, P.; CONSTANTINO, P. de A. L.; PIONTEKOWSKI, V. **Terras Indígenas na Amazônia Brasileira: reservas de carbono e barreiras ao desmatamento**. [s.l.: s.n.]16 p.

CRISP, D.; FISHER, B. M.; O'DELL, C.; FRANKENBERG, C.; BASILIO, R.; BÖSCH, H.; BROWN, L. R.; CASTANO, R.; CONNOR, B.; DEUTSCHER, N. M.; ELDERING, A.; GRIFFITH, D.; GUNSON, M.; KUZE, A.; MANDRAKE, L.; MCDUFFIE, J.; MESSERSCHMIDT, J.; MILLER, C. E.; MORINO, I.; NATRAJ, V.; NOTHOLT, J.; O'BRIEN, D. M.; OYAFUSO, F.; POLONSKY, I.; ROBINSON, J.; SALAWITCH, R.; SHERLOCK, V.; SMYTH, M.; SUTO, H.; TAYLOR, T. E.; THOMPSON, D. R.; WENNBERG, P. O.; WUNCH, D.; YUNG, Y. L. The ACOS CO₂ retrieval algorithm – Part II: Global XCO₂ data characterization. **Atmospheric Measurement Techniques**, v. 5, n. 4, p. 687–707, 2 abr. 2012. Disponível em: <<https://amt.copernicus.org/articles/5/687/2012/>>.

DA ROCHA, H. R.; MANZI, A. O.; CABRAL, O. M.; MILLER, S. D.; GOULDEN, M. L.; SALESKA, S. R.; R.-COUPE, N.; WOFSY, S. C.; BORMA, L. S.; ARTAXO, P.; VOURLITIS, G.; NOGUEIRA, J. S.; CARDOSO, F. L.; NOBRE, A. D.; KRUIJT, B.; FREITAS, H. C.; VON RANDOW, C.; AGUIAR, R. G.; MAIA, J. F. Patterns of water and heat flux across a biome gradient from tropical forest to savanna in Brazil. **Journal of Geophysical Research**, v. 114, G00B12, 17 jan. 2009.

DA SILVA JUNIOR, C. A.; LIMA, M.; TEODORO, P. E.; DE OLIVEIRA-JÚNIOR, J. F.; ROSSI, F. S.; FUNATSU, B. M.; BUTTURI, W.; LOURENÇONI, T.; KRAESKI, A.; PELISSARI, T. D.; MORATELLI, F. A.; ARVOR, D.; LUZ, I. M. D. S.; TEODORO, L. P. R.; DUBREUIL, V.; TEIXEIRA, V. M. Fires drive long-term environmental degradation in the Amazon Basin. **Remote Sensing**, v. 14, n. 2, 338, 1 jan. 2022. Disponível em: <<https://www.mdpi.com/2072-4292/14/2/338/htm>>. Acesso em: 23 ago. 2022.

DA SILVA JÚNIOR, L. A. S.; DELGADO, R. C.; PEREIRA, M. G.; TEODORO, P. E.; DA SILVA JUNIOR, C. A. Fire dynamics in extreme climatic events in western Amazon. **Environmental Development**, v. 32, 100450, 2019.

DE OLIVEIRA, G.; BRUNSELL, N. A.; CHEN, J. M.; SHIMABUKURO, Y. E.; MATAVELI, G. A. V.; DOS SANTOS, C. A. C.; STARK, S. C.; DE LIMA, A.; ARAGÃO, L. E. O. C. Legacy effects following fire on surface energy, water and carbon fluxes in mature Amazonian forests. **Journal of Geophysical Research: Biogeosciences**, v. 126, n. 5, e2020JG005833, 7 maio 2021.

DE OLIVEIRA-JÚNIOR, J. F.; DA SILVA JUNIOR, C. A.; TEODORO, P. E.; ROSSI, F. S.; BLANCO, C. J. C.; LIMA, M.; DE GOIS, G.; CORREIA FILHO, W. L. F.; DE BARROS

SANTIAGO, D.; DOS SANTOS VANDERLEY, M. H. G. Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. **International Journal of Climatology**, v. 41, n. 9, p. 4478–4493, 2021. Disponível em: <<https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/joc.7080>>.

DELGADO, R. C.; PEREIRA, M. G.; TEODORO, P. E.; DOS SANTOS, G. L.; DE CARVALHO, D. C.; MAGISTRALI, I. C.; VILANOVA, R. S. Seasonality of gross primary production in the Atlantic Forest of Brazil. **Global Ecology and Conservation**, v. 14, e00392, 1 abr. 2018. Acesso em: 27 set. 2021.

DELLA-SILVA, J. L.; SILVA JUNIOR, C. A. da; LIMA, M.; TEODORO, P. E.; NANNI, M. R.; SHIRATSUCHI, L. S.; TEODORO, L. P. R.; CAPRISTO-SILVA, G. F.; BAIIO, F. H. R.; DE OLIVEIRA, G.; DE OLIVEIRA-JÚNIOR, J. F.; ROSSI, F. S. CO₂Flux model assessment and comparison between an airborne hyperspectral sensor and orbital multispectral imagery in Southern Amazonia. **Sustainability**, v. 14, n. 9, 5458, 1 mai. 2022. Disponível em: <<https://www.mdpi.com/2071-1050/14/9/5458/htm>>. Acesso em: 21 jun. 2022.

DENG, F.; JONES, D. B. A.; O'DELL, C. W.; NASSAR, R.; PARAZOO, N. C. Combining GOSAT X CO₂ observations over land and ocean to improve regional CO₂ flux estimates. **Journal of Geophysical Research: Atmospheres**, v. 121, n. 4, p. 1896–1913, 27 fev. 2016.

DÍAZ ARANGO, A. **Captura de carbono en un sistema agroforestal con cacao (Theobroma cacao) en Victoria, Caldas**. 2023.

DIRIKOLU, L.; WALLER, P.; MALVEAUX, K.; LUCAS, C. H.; LOMNICKA, I.; POURCIAU, A.; BENNADJI, H.; LIU, C.-C. Total carbon dioxide (TCO₂) concentrations in thoroughbred and quarter racehorses in Louisiana. **Journal of Equine Veterinary Science**, v. 121, 104220, fev. 2023.

DUARTE, M. L.; SOUSA, J. A. P. de; CASTRO, A. L. de; LOURENÇO, R. W. Dynamics of land use in a rural settlement in the Brazilian Legal Amazon. **Revista Brasileira de Ciências Ambientais**, v. 56, n. 3, p. 375–384, 17 ago. 2021.

DUBREUIL, V.; FANTE, K. P.; PLANCHON, O.; NETO, J. L. S. Os tipos de climas anuais no Brasil: Uma aplicação da classificação de Köppen de 1961 a 2015. **Revista Franco-Brasileira de Geografia**, v. 37, p. 1–26, 24 set. 2018. Disponível em: <<http://journals.openedition.org/confins/15738>>. Acesso em: 23 set. 2021.

ESA. **GOSAT Objectives.** Disponível em: <<https://earth.esa.int/eogateway/missions/gosat/description>>. Acesso em: 5 fev. 2022.

EVERITT, B. S.; DUNN, G. **Applied multivariate data analysis.** [s.l: s.n.]

FAJARDO, A.; GUNDALE, M. J. Combined effects of anthropogenic fires and land-use change on soil properties and processes in Patagonia, Chile. **Forest Ecology and Management**, v. 357, p. 60–67, dez. 2015. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0378112715004375>>.

FARIA, T. de O.; RODRIGUES, T. R.; CURADO, L. F. A.; GAIO, D. C.; NOGUEIRA, J. de S. Surface albedo in different land-use and cover types in Amazon forest region. **Revista Ambiente e Água**, v. 13, n. 2, 2018. Acesso em: 23 ago. 2022.

FELTON, A. J.; GOLDSMITH, G. R. Timing and magnitude of drought impacts on carbon uptake across a grassland biome. **Global Change Biology**, v. 29, p. 2790-2803, 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/gcb.16637>>. Acesso em: 19 mar. 2023.

FERREIRA BARBOSA, M. L.; DELGADO, R. C.; FORSAD DE ANDRADE, C.; TEODORO, P. E.; SILVA JUNIOR, C. A.; WANDERLEY, H. S.; CAPRISTO-SILVA, G. F. Recent trends in the fire dynamics in Brazilian Legal Amazon: Interaction between the ENSO phenomenon, climate and land use. **Environmental Development**, v. 39, 1 set. 2021. . Acesso em: 23 ago. 2022.

FIELD, C. B.; RANDERSON, J. T.; MALMSTRÖM, C. M. Global net primary production: Combining ecology and remote sensing. **Remote Sensing of Environment**, v. 51, n. 1, p. 74–88, 1995.

FLACH, R.; ABRAHÃO, G.; BRYANT, B.; SCARABELLO, M.; SOTERRONI, A. C.; RAMOS, F. M.; VALIN, H.; OBERSTEINER, M.; COHN, A. S. Conserving the Cerrado and Amazon biomes of Brazil protects the soy economy from damaging warming. **World Development**, v. 146, 105582, 2021.

FRIEDL, M.; SULLA-MENASHE, D. **MCD12Q1 MODIS/Terra+Aqua Land Cover Tipo Anual L3 Global 500m SIN Grid V006.** Disponível em: <<https://lpdaac.usgs.gov/products/mcd12q1v006/>>. Acesso em: 21 jun. 2022.

FRIEDLINGSTEIN, P.; HOUGHTON, R. A.; MARLAND, G.; HACKLER, J.; BODEN, T. A.; CONWAY, T. J.; CANADELL, J. G.; RAUPACH, M. R.; CIAIS, P.; LE QUÉRÉ, C. Update on CO₂ emissions. **Nature Geoscience**, v. 3, n. 12, p. 811–812, 21 dez. 2010.

FUNAI, F. N. do I. **Terras Indígenas**. Disponível em: <<https://metadados.snirh.gov.br/geonetwork/srv/api/records/3fa8cc38-79b4-4aa1-8179-bba315baea4b>>. Acesso em: 28 jun. 2022.

FUNK, C. C.; PETERSON, P. J.; LANDSFELD, M. F.; PEDREROS, D. H.; VERDIN, J. P.; ROWLAND, J. D.; ROMERO, B. E.; HUSAK, G. J.; MICHAELSEN, J. C.; VERDIN, A. P. A quasi-global precipitation time series for drought monitoring. **Data Series**. [s.l.: s.n.]. Disponível em: <<http://pubs.er.usgs.gov/publication/ds832>>.

GAMON, J.; SERRANO, L.; SURFUS, J. S. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. **Oecologia**, v. 112, p. 492–501, 1997.

GETIS, A.; ORD, J. K. The analysis of spatial association by use of distance statistics. **Geographical Analysis**. [s.l.: s.n.] p. 189–206.

GHOSH, A.; SHARMA, R.; JOSHI, P. K. Random forest classification of urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion. **Applied Geography**, v. 48, p. 31–41, mar. 2014. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0143622814000046>>.

GILLANDERS, S. N.; COOPS, N. C.; WULDER, M. A.; GERGEL, S. E.; NELSON, T. Multitemporal remote sensing of landscape dynamics and pattern change: Describing natural and anthropogenic trends. **Progress in Physical Geography: Earth and Environment**, v. 32, n. 5, p. 503–528, 1 out. 2008.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, dez. 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0034425717302900>>.

HE, S.; LI, J.; WANG, J.; LIU, F. Evaluation and analysis of upscaling of different land use/land cover products (FORM-GLC30, GLC_FCS30, CCI_LC, MCD12Q1 and CNLUCC): a case

study in China. **Geocarto International**, v. 37, p. 17340-17360, 9 out. 2022. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/10106049.2022.2127926>>.

HEINRICH, V. H. A.; DALAGNOL, R.; CASSOL, H. L. G.; ROSAN, T. M.; DE ALMEIDA, C. T.; SILVA JUNIOR, C. H. L.; CAMPANHARO, W. A.; HOUSE, J. I.; SITCH, S.; HALES, T. C.; ADAMI, M.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, n. 1, p. 1785, 2021. Disponível em: <<https://www.science.org/doi/10.1038/s41467-021-22050-1>>. Acesso em: 13 set. 2023.

HEINSCH, F. A.; REEVES, M.; VOTAVA, P.; KANG, S. Y.; MILESI, C.; ZHAO, M. S.; GLASSY, J.; JOLLY, W. M.; LOEHMAN, R.; BOWKER, C. F.; KIMBALL, J. S.; NEMANI, R. R.; RUNNING, S. W. **User's guide GPP and NPP (MOD17A2/A3) products NASA MODIS land algorithm.** Disponível em: <https://www.researchgate.net/publication/242118371_User's_guide_GPP_and_NPP_MOD17A2A3_products_NASA_MODIS_land_algorithm>. Acesso em: 26 set. 2021.

HERRERA, D.; PFAFF, A.; ROBALINO, J. Impacts of protected areas vary with the level of government: Comparing avoided deforestation across agencies in the Brazilian Amazon. **Proceedings of the National Academy of Sciences**, v. 116, n. 30, p. 14916–14925, 23 jul. 2019.

HERVÉ, M. Aide-mémoire de statistique appliquée à la biologie - Construire son étude et analyser les résultats à l'aide du logiciel R. 203 p., 2016.

HUESCA, M.; LITAGO, J.; PALACIOS-ORUETA, A.; MONTES, F.; SEBASTIÁN-LÓPEZ, A.; ESCRIBANO, P. Assessment of forest fire seasonality using MODIS fire potential: A time series approach. **Agricultural and Forest Meteorology**, v. 149, n. 11, p. 1946–1955, nov. 2009. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168192309001658>>.

HUI, D.; DENG, Q.; TIAN, H.; LUO, Y. Climate change and carbon sequestration in forest ecosystems. *Em: Handbook of Climate Change Mitigation and Adaptation*. New York, NY: Springer New York, 2015. p. 1–40.

IBGE. **Biomass e Sistema Costeiro-Marinho do Brasil: compatível com a escala 1:250.000**. Rio de Janeiro: IBGE, 2019. 168 p.

IBGE. **Conheça Cidades e Estados do Brasil**. Disponível em: <<https://cidades.ibge.gov.br/>>. Acesso em: 21 nov. 2020.

IBGE. **Amazônia Legal**. Disponível em: <<https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=o-que-e>>. Acesso em: 23 set. 2021.

INPE. **PRODES — Coordenação-Geral de Observação da Terra**. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 14 set. 2021.

INPE-PRODES. **Projeto de Monitoramento do Desmatamento na Amazônia Brasileira por Satélite (Monitoring Deforestation in the Brazilian Amazon by Satellite Project)**. Disponível em: <<http://www.obt.inpe.br/prodes>>.

JIMÉNEZ-MUÑOZ, J. C.; MATTAR, C.; BARICHIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J. A.; VAN DER SCHRIER, G. **Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015-2016**. 2016. Disponível em: <www.nature.com/scientificreports/>. Acesso em: 26 jun. 2023.

KATAOKA, F.; KNUTESON, R. O.; KUZE, A.; SHIOMI, K.; SUTO, H.; YOSHIDA, J.; KONDOH, S.; SAITOH, N. Calibration, Level 1 processing, and radiometric validation for TANSO-FTS TIR on GOSAT. **IEEE Transactions on Geoscience and Remote Sensing**, v. 57, n. 6, p. 3490–3500, jun. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8587125/>>.

KESSTRA, S. D.; MAROULIS, J.; ARGAMAN, E.; VOOGT, A.; WITTENBERG, L. Effects of controlled fire on hydrology and erosion under simulated rainfall. **Cuadernos de Investigación Geográfica**, v. 40, n. 2, p. 269–294, 7 mar. 2014. Disponível em: <<https://publicaciones.unirioja.es/ojs/index.php/cig/article/view/2532>>.

KENDALL, M. **Rank Correlation Methods**. London: Charles Griffin, 1975. 120 p.

KNAPP, K. R.; ANSARI, S.; BAIN, C. L.; BOURASSA, M. A.; DICKINSON, M. J.; FUNK, C.; HELMS, C. N.; HENNON, C. C.; HOLMES, C. D.; HUFFMAN, G. J.; KOSSIN, J. P.; LEE, H. T.; LOEW, A.; MAGNUSDOTTIR, G. Globally gridded satellite observations for

climate studies. **Bulletin of the American Meteorological Society**, v. 92, n. 7, p. 893–907, jul. 2011. Acesso em: 23 ago. 2022.

KOZAK, M. **O que é correlação forte?** 31. ed. [s.l.] Ensinar, 2009. 85–86 p.

KROEGER, M. E.; WANG, R. Z.; SUAZO, D.; DUNBAR, J. Simulated nitrogen deposition and precipitation events alter microbial carbon cycling during early stages of litter decomposition. **Scientific Reports**, v. 11, 1748, 2021.

KUZE, A.; SUTO, H.; NAKAJIMA, M.; HAMAZAKI, T. Thermal and near infrared sensor for carbon observation Fourier-transform spectrometer on the Greenhouse Gases Observing Satellite for greenhouse gases monitoring. **Applied Optics**, v. 48, n. 35, 6716, 10 dez. 2009.

LE QUÉRÉ, C.; MORIARTY, R.; ANDREW, R. M.; CANADELL, J. G.; SITCH, S.; KORSBAKKEN, J. I.; FRIEDLINGSTEIN, P.; PETERS, G. P.; ANDRES, R. J.; BODEN, T. A.; HOUGHTON, R. A.; HOUSE, J. I.; KEELING, R. F.; TANS, P.; ARNETH, A.; BAKKER, D. C. E.; BARBERO, L.; BOPP, L.; CHANG, J.; CHEVALLIER, F.; CHINI, L. P.; CIAIS, P.; FADER, M.; FEELY, R. A.; GKRTZALIS, T.; HARRIS, I.; HAUCK, J.; ILYINA, T.; JAIN, A. K.; KATO, E.; KITIDIS, V.; KLEIN GOLDEWIJK, K.; KOVEN, C.; LANDSCHÜTZER, P.; LAUVSET, S. K.; LEFÈVRE, N.; LENTON, A.; LIMA, I. D.; METZL, N.; MILLERO, F.; MUNRO, D. R.; MURATA, A.; NABEL, J. E. M. S.; NAKAOKA, S.; NOJIRI, Y.; O'BRIEN, K.; OLSEN, A.; ONO, T.; PÉREZ, F. F.; PFEIL, B.; PIERROT, D.; POULTER, B.; REHDER, G.; RÖDENBECK, C.; SAITO, S.; SCHUSTER, U.; SCHWINGER, J.; SÉFÉRIAN, R.; STEINHOFF, T.; STOCKER, B. D.; SUTTON, A. J.; TAKAHASHI, T.; TILBROOK, B.; VAN DER LAAN-LUIJKX, I. T.; VAN DER WERF, G. R.; VAN HEUVEN, S.; VANDEMARK, D.; VIOVY, N.; WILTSHIRE, A.; ZAEHLE, S.; ZENG, N. Global carbon budget 2015. **Earth System Science Data**, v. 7, n. 2, p. 349–396, 7 dez. 2015.

LIMA, M.; SANTANA, D. C.; JUNIOR, I. C. M.; COSTA, P. M. C. da; OLIVEIRA, P. P. G. de; AZEVEDO, R. P. de; SILVA, R. de S.; MARINHO, U. de F.; SILVA, V. da; SOUZA, J. A. A. de; ROSSI, F. S.; DELGADO, R. C.; TEODORO, L. P. R.; TEODORO, P. E.; SILVA JUNIOR, C. A. da. The “New Transamazonian Highway”: BR-319 and its current environmental degradation. **Sustainability**, v. 14, n. 2, 823, 12 jan. 2022. Disponível em: <<https://www.mdpi.com/2071-1050/14/2/823>>.

LIMA, M.; VALE, J. C. E. do; COSTA, G. de M.; SANTOS, R. C. dos; CORREIA FILHO, W. L. F.; GOIS, G.; OLIVEIRA-JUNIOR, J. F. de; TEODORO, P. E.; ROSSI, F. S.; DA SILVA JUNIOR, C. A. The forests in the indigenous lands in Brazil in peril. **Land Use Policy**, v. 90, 104258, 1 jan. 2020. Acesso em: 23 ago. 2022.

LIN, X.; CHEN, B.; CHEN, J.; ZHANG, H.; SUN, S.; XU, G.; GUO, L.; GE, M.; QU, J.; LI, L.; KONG, Y. Seasonal fluctuations of photosynthetic parameters for light use efficiency models and the impacts on gross primary production estimation. **Agricultural and Forest Meteorology**, v. 236, p. 22–35, abr. 2017.

LINDSEY, R. **Climate Change: Atmospheric Carbon Dioxide**. . Acesso em: 10 maio. 2020.

LOVEJOY, T. E.; NOBRE, C. Amazon tipping point. **Science Advances**, v. 4, n. 2, 2 fev. 2018.

LOVEJOY, T. E.; NOBRE, C. Amazon tipping point: Last chance for action. **Science Advances**, v. 5, n. 12, eaba2949, 6 dez. 2019.

MACFARLAND, T. W.; YATES, J. M. **Using R for Biostatistics**. Cham: Springer International Publishing, 2021.

MANN, H. B. Nonparametric tests against trend. **Econometrica**, v. 13, n. 3, p. 245–259, 1945. Disponível em: <<http://www.jstor.com/stable/1907187>>.

MARENGO, J. A.; ESPINOZA, J. C. Extreme seasonal droughts and floods in Amazonia: causes, trends and impacts. **International Journal of Climatology**, v. 36, n. 3, p. 1033–1050, 29 mar. 2016.

MATAVELI, G.; DE OLIVEIRA, G. Protect the Amazon's Indigenous lands. **Science**, v. 375, n. 6578, p. 275–276, 21 jan. 2022. Disponível em: <<https://www.science.org/doi/10.1126/science.abn4936>>. Acesso em: 1 abr. 2023.

MINISTÉRIO DO MEIO AMBIENTE. **Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm)**. Brasília: MMA.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. **The Journal of Applied Ecology**, v. 9, n. 3, 747, dez. 1972. Acesso em: 1 abr. 2023.

MUSTAFA, F.; BU, L.; WANG, Q.; ALI, Md.; BILAL, M.; SHAHZAMAN, M.; QIU, Z. Multi-Year Comparison of CO₂ concentration from NOAA carbon tracker reanalysis model

with data from GOSAT and OCO-2 over Asia. **Remote Sensing**, v. 12, n. 15, p. 2498, 4 ago. 2020.

MUSTAFA, F.; WANG, H.; BU, L.; WANG, Q.; SHAHZAMAN, M.; BILAL, M.; ZHOU, M.; IQBAL, R.; ASLAM, R. W.; ALI, Md. A.; QIU, Z. Validation of GOSAT and OCO-2 against in situ aircraft measurements and comparison with carbontracker and GEOS-Chem over Qinhuangdao, China. **Remote Sensing**, v. 13, n. 5, 899, 27 fev. 2021.

NOAA. National Oceanic and Atmospheric Administration. **NOAA's Climate Prediction Center**. Disponível em: <https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php>. Acesso em: 13 mar. 2023.

OLIVEIRA, G. de; CHEN, J. M.; MATAVELI, G. A. V.; CHAVES, M. E. D.; SEIXAS, H. T.; CARDOZO, F. da S.; SHIMABUKURO, Y. E.; HE, L.; STARK, S. C.; SANTOS, C. A. C. dos. Rapid recent deforestation incursion in a vulnerable indigenous land in the Brazilian Amazon and fire-driven emissions of fine particulate aerosol pollutants. **Forests**, v. 11, n. 8, 829, 30 jul. 2020. Disponível em: <<https://www.mdpi.com/1999-4907/11/8/829/htm>>. Acesso em: 9 set. 2021.

PAN, Y.; BIRDSEY, R. A.; FANG, J.; HOUGHTON, R.; KAUPPI, P. E.; KURZ, W. A.; PHILLIPS, O. L.; SHVIDENKO, A.; LEWIS, S. L.; CANADELL, J. G.; CIAIS, P.; JACKSON, R. B.; PACALA, S. W.; MCGUIRE, A. D.; PIAO, S.; RAUTIAINEN, A.; SITCH, S.; HAYES, D. A Large and persistent carbon sink in the world's forests. **Science**, v. 333, n. 6045, p. 988–993, 19 ago. 2011. Disponível em: <<https://www.science.org/doi/10.1126/science.1201609>>.

PERES, C. **Arco do Desmatamento, Brasil | Prêmio Whitley**. Disponível em: <<https://whitleyaward.org/winners/informed-landscape-management-brazil/>>. Acesso em: 13 mar. 2023.

PETTITT, A. N. A non-parametric approach to the change-point problem. **Applied Statistics**, v. 28, n. 2, 126, 1979. Disponível em: <<https://www.jstor.org/stable/10.2307/2346729>>.

QIN, Y.; XIAO, X.; LIU, F.; DE SA E SILVA, F.; SHIMABUKURO, Y.; ARAI, E.; FEARNSIDE, P. M. Forest conservation in Indigenous territories and protected areas in the Brazilian Amazon. **Nature Sustainability**, v. 6, n. 3, p. 295-305, mar. 2023.

QIN, Y.; XIAO, X.; WIGNERON, J.-P.; CIAIS, P.; BRANDT, M.; FAN, L.; LI, X.; CROWELL, S.; WU, X.; DOUGHTY, R.; ZHANG, Y.; LIU, F.; SITCH, S.; MOORE, B. Carbon loss from forest degradation exceeds that from deforestation in the Brazilian Amazon. **Nature Climate Change**, v. 11, n. 5, p. 442–448, 29 mai. 2021.

R CORE TEAM. **R: A language and environment for statistical computing. R Foundation for Statistical Computing.** Vienna, Austria. 2018. Disponível em: <<https://www.r-project.org/>>.

RAHMAN, A. F.; GAMON, J. A.; FUENTES, D. A.; ROBERTS, D. A.; PRENTISS, D. Modeling spatially distributed ecosystem flux of boreal forest using hyperspectral indices from AVIRIS imagery. **Journal of Geophysical Research Atmospheres**, v. 106, n. D24, p. 33579–33591, 2001.

RAJU, A.; SIJIKUMAR, S.; KUMAR, P.; BURMAN, D.; VALSALA, V.; TIWARI, Y. K.; MUKHERJEE, S.; LOHANI, P.; KUMAR, K. Very high-resolution net ecosystem exchange over India using vegetation photosynthesis and respiration model (VPRM) simulations. **Ecological Modelling**, v. 481, 110340, 1 jul. 2023. Disponível em: <<https://doi.org/10.1016/j.ecolmodel.2023.110340>>. Acesso em: 18 mar. 2023.

RAMMIG, A.; LAPOLA, D. M. The declining tropical carbon sink. **Nature Climate Change**, v. 11, n. 9, p. 727–728, 30 set. 2021. Disponível em: <<https://www.nature.com/articles/s41558-021-01135-1>>.

REGAZZI, A. J.; CRUZ, C. D. Análise multivariada aplicada. **Editora UFV, Viçosa, 401p**, 2020.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma cerrado. *Em*: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. 2. ed. Brasília: EMBRAPA-CERRADOS, 2008. p. 876.

ROSSI, F. S.; DE ARAÚJO SANTOS, G. A.; DE SOUZA MARIA, L.; LOURENÇONI, T.; PELISSARI, T. D.; DELLA-SILVA, J. L.; OLIVEIRA JÚNIOR, J. W.; SILVA, A. de A. e; LIMA, M.; TEODORO, P. E.; TEODORO, L. P. R.; DE OLIVEIRA-JÚNIOR, J. F.; LA SCALA JR, N.; SILVA JUNIOR, C. A. da. Carbon dioxide spatial variability and dynamics for contrasting land uses in central Brazil agricultural frontier from remote sensing data. **Journal**

of **South American Earth Sciences**, v. 116, p. 103809, jun. 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0895981122001006>>.

ROSSI, F. S.; SANTOS, G. A. de A. Fire dynamics in Mato Grosso State, Brazil: The relative roles of gross primary productivity. **Big Earth Data**, v. 4, n. 1, p. 23–44, jan. 2020.

ROSSI, F. S.; SILVA JUNIOR, C. A. da; OLIVEIRA-JÚNIOR, J. F. de; TEODORO, P. E.; SHIRATSUCHI, L. S.; LIMA, M.; TEODORO, L. P. R.; TIAGO, A. V.; CAPRISTO-SILVA, G. F. 19-Year remotely sensed data in the forecast of spectral models of the environment. **International Journal of Digital Earth**, v. 14, n. 8, p. 1040-1066, mai. 2021.

ROY, B. A machine learning approach to monitoring and forecasting spatio-temporal dynamics of land cover in Cox's Bazar district, Bangladesh from 2001 to 2019. **Environmental Challenges**, v. 5, 100237, 1 dez. 2021. Acesso em: 30 mar. 2022.

RUNNING, S. W.; ZHAO, M. User's Guide Daily GPP and Annual NPP (MOD17A2H/A3H) and Year-end Gap- Filled (MOD17A2HGF/A3HGF) Products NASA Earth Observing System MODIS Land Algorithm (For. p. 1–37, 2019. Disponível em: <https://lpdaac.usgs.gov/documents/379/MOD17_User_Guide_V6.pdf>.

SANTOS, G. A. de A.; MORAIS FILHO, L. F. F.; MENESES, K. C. de; SILVA JUNIOR, C. A. da; ROLIM, G. de S.; LA SCALA, N. Hot spots and anomalies of CO₂ over eastern Amazonia, Brazil: A time series from 2015 to 2018. **Environmental Research**, v. 215, 114379, dez. 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0013935122017066>>.

SCHIELEIN, J.; BÖRNER, J. Recent transformations of land-use and land-cover dynamics across different deforestation frontiers in the Brazilian Amazon. **Land Use Policy**, v. 76, p. 81–94, 1 jul. 2018. Acesso em: 13 set. 2021.

SHAH, R.; BHARADIYA, N.; MANEKAR, V. Drought index computation using Standardized Precipitation Index (SPI) method for Surat District, Gujarat. **Aquatic Procedia**, v. 4, p. 1243–1249, 2015.

SILVA, C. H. L.; ARAGÃO, L. E. O. C.; ANDERSON, L. O.; FONSECA, M. G.; SHIMABUKURO, Y. E.; VANCUTSEM, C.; ACHARD, F.; BEUCHLE, R.; NUMATA, I.; SILVA, C. A.; MAEDA, E. E.; LONGO, M.; SAATCHI, S. S. Persistent collapse of biomass

in Amazonian forest edges following deforestation leads to unaccounted carbon losses. **Science Advances**, v. 6, n. 40, eaaz8360, 30 set. 2020a. Acesso em: 14 set. 2021.

SILVA, C. V. J.; ARAGÃO, L. E. O. C.; YOUNG, P. J.; ESPIRITO-SANTO, F.; BERENGUER, E.; ANDERSON, L. O.; BRASIL, I.; PONTES-LOPES, A.; FERREIRA, J.; WITHEY, K.; FRANÇA, F.; GRAÇA, P. M. L. A.; KIRSTEN, L.; XAUD, H.; SALIMON, C.; SCARANELLO, M. A.; CASTRO, B.; SEIXAS, M.; FARIAS, R.; BARLOW, J. Estimating the multi-decadal carbon deficit of burned Amazonian forests. **Environmental Research Letters**, v. 15, n. 11, 114023, 26 out. 2020b. Disponível em: <<https://doi.org/10.1088/1748-9326/abb62c>>. Acesso em: 14 set. 2021.

SILVA, L. A. P. da; SOUZA, C. M. P. de; SILVA, C. R. da; BOLFE, É. L.; ROCHA, A. M. Projection of climate change impacts on net primary productivity of the Legal Amazon – Brazil. **Caderno de Geografia**, v. 33, n. 72, p. 110–130, 2023.

SILVA JUNIOR, C. H. L.; CARVALHO, N. S.; PESSÔA, A. C. M.; REIS, J. B. C.; PONTES-LOPES, A.; DOBLAS, J.; HEINRICH, V.; CAMPANHARO, W.; ALENCAR, A.; SILVA, C.; LAPOLA, D. M.; ARMENTERAS, D.; MATRICARDI, E. A. T.; BERENGUER, E.; CASSOL, H.; NUMATA, I.; HOUSE, J.; FERREIRA, J.; BARLOW, J.; GATTI, L.; BRANDO, P.; FEARNSIDE, P. M.; SAATCHI, S.; SILVA, S.; SITCH, S.; AGUIAR, A. P.; SILVA, C. A.; VANCUTSEM, C.; ACHARD, F.; BEUCHLE, R.; SHIMABUKURO, Y. E.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. Amazonian forest degradation must be incorporated into the COP26 agenda. **Nature Geoscience**, v. 14, n. 9, p. 634–635, 2 set. 2021. Disponível em: <<https://www.mdpi.com/1999-4907/11/8/829>>. Acesso em: 9 set. 2021.

SILVA JUNIOR, C. A. da; COSTA, G. de M.; ROSSI, F. S.; VALE, J. C. E. do; LIMA, R. B. de; LIMA, M.; OLIVEIRA-JUNIOR, J. F. de; TEODORO, P. E.; SANTOS, R. C. Remote sensing for updating the boundaries between the Brazilian Cerrado-Amazonia biomes. **Environmental Science & Policy**, v. 101, p. 383–392, nov. 2019a. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S146290111831400X>>.

SILVA JUNIOR, C. A. da; LIMA, M.; TEODORO, P. E.; OLIVEIRA-JÚNIOR, J. F. de; ROSSI, F. S.; FUNATSU, B. M.; BUTTURI, W.; LOURENÇONI, T.; KRAESKI, A.; PELISSARI, T. D.; MORATELLI, F. A.; ARVOR, D.; LUZ, I. M. dos S.; TEODORO, L. P. R.; DUBREUIL, V.; TEIXEIRA, V. M. Fires drive long-term environmental degradation in the Amazon Basin. **Remote Sensing**, v. 14, n. 2, p. 338, 12 jan. 2022.

SILVA JUNIOR, C. A. da; NANNI, M. R.; OLIVEIRA-JÚNIOR, J. F. de; CEZAR, E.; TEODORO, P. E.; DELGADO, R. C.; SHIRATSUCHI, L. S.; SHAKIR, M.; CHICATI, M. L. Object-based image analysis supported by data mining to discriminate large areas of soybean. **International Journal of Digital Earth**, v. 12, n. 3, p. 270–292, mar. 2019b.

SILVEIRA, F. A. O.; FERREIRA, M. C.; PERILLO, L. N.; CARMO, F. F.; NEVES, F. S. Brazil's protected areas under threat. **Science**, v. 361, n. 6401, p. 459–459, 3 ago. 2018.

SMITH, M. N.; STARK, S. C.; TAYLOR, T. C.; SCHIETTI, J.; DE ALMEIDA, D. R. A.; ARAGÓN, S.; TORRALVO, K.; LIMA, A. P.; DE OLIVEIRA, G.; DE ASSIS, R. L.; LEITOLD, V.; PONTES-LOPES, A.; SCOLES, R.; DE SOUSA VIEIRA, L. C.; RESENDE, A. F.; COPPOLA, A. I.; BRANDÃO, D. O.; DE ATHAYDES SILVA JUNIOR, J.; LOBATO, L. F.; FREITAS, W.; ALMEIDA, D.; SOUZA, M. S.; MINOR, D. M.; VILLEGAS, J. C.; LAW, D. J.; GONÇALVES, N.; DA ROCHA, D. G.; GUEDES, M. C.; TONINI, H.; DA SILVA, K. E.; VAN HAREN, J.; ROSA, D. M.; DO VALLE, D. F.; CORDEIRO, C. L.; DE LIMA, N. Z.; SHAO, G.; MENOR, I. O.; CONTI, G.; FLORENTINO, A. P.; MONTTI, L.; ARAGÃO, L. E. O. C.; MCMAHON, S. M.; PARKER, G. G.; BRESHEARS, D. D.; DA COSTA, A. C. L.; MAGNUSSON, W. E.; MESQUITA, R.; CAMARGO, J. L. C.; DE OLIVEIRA, R. C.; DE CAMARGO, P. B.; SALESKA, S. R.; NELSON, B. W. Diverse anthropogenic disturbances shift Amazon forests along a structural spectrum. **Frontiers in Ecology and the Environment**, v. 21, n. 1, p. 24–32, 1 fev. 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/fee.2590>>. Acesso em: 1 abr. 2023.

STAAL, A.; FLORES, B. M.; AGUIAR, A. P. D.; BOSMANS, J. H. C.; FETZER, I.; TUINENBURG, O. A. Feedback between drought and deforestation in the Amazon. **Environmental Research Letters**, v. 15, n. 4, 044024, 2 abr. 2020. Disponível em: <<https://iopscience.iop.org/article/10.1088/1748-9326/ab738e>>. Acesso em: 13 set. 2021.

STARK, S. C.; BRESHEARS, D. D.; ARAGÓN, S.; VILLEGAS, J. C.; LAW, D. J.; SMITH, M. N.; MINOR, D. M.; ASSIS, R. L.; ALMEIDA, D. R. A.; OLIVEIRA, G.; SALESKA, S. R.; SWANN, A. L.; MOURA, J. M. S.; CAMARGO, J. L.; SILVA, R.; O C ARAGÃO, L. E. O. C.; COSME OLIVEIRA, R. Reframing tropical savannization: Linking changes in canopy structure to energy balance alterations that impact climate. **Ecosphere**, v. 11, n. 9, e03231, set. 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/ecs2.3231>>. Acesso em: 1 abr. 2023.

SULLA-MENASHE, D.; FRIEDL, M. A. User guide to collection 6 MODIS land cover (MCD12Q1) product. 2018. Disponível em: <<https://doi.org/10.5067/MODIS/MCD12Q1.006>>. Acesso em: 26 set. 2021.

TEODORO, P. E.; CORRÊA, C. C. G.; TORRES, F. E.; DE OLIVEIRA-JÚNIOR, J. F.; DA SILVA JUNIOR, C. A.; GOIS, G.; DELGADO, R. C. Analysis of the occurrence of wet and drought periods using standardized precipitation index in Mato Grosso do Sul State, Brazil. **Journal of Agronomy**, v. 14, n. 2, p. 80–86, 7 jul. 2015. Acesso em: 23 ago. 2022.

TOTÉ, C.; PATRICIO, D.; BOOGAARD, H.; VAN DER WIJNGAART, R.; TARNAVSKY, E.; FUNK, C. Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. **Remote Sensing**, v. 7, n. 2, p. 1758–1776, 2015. Acesso em: 23 ago. 2022.

TOWNER, J.; CLOKE, H. L.; LAVADO, W.; SANTINI, W.; BAZO, J.; COUGHLAN DE PEREZ, E.; STEPHENS, E. M. Attribution of Amazon floods to modes of climate variability: A review. **Meteorological Applications**, v. 27, n. 5, p. 6347–6352, 18 set. 2020.

VERMOTE, E. **MOD09A1.006 Terra Surface Reflectance 8-Day Global 500m**. Disponível em: <<https://lpdaac.usgs.gov/products/mod09a1v006/>>. Acesso em: 11 jul. 2022.

WAGLE, P.; ZHANG, Y.; JIN, C.; XIAO, X. Comparison of solar-induced chlorophyll fluorescence, light-use efficiency, and process-based GPP models in maize. **Ecological Applications**, v. 26, n. 4, p. 1211–1222, 8 jun. 2016.

WAGNER, F. H.; HÉRAULT, B.; ROSSI, V.; HILKER, T.; MAEDA, E. E.; SANCHEZ, A.; LYAPUSTIN, A. I.; GALVÃO, L. S.; WANG, Y.; ARAGÃO, L. E. O. C. Climate drivers of the Amazon forest greening. **PLOS ONE**, v. 12, n. 7, e0180932, 14 jul. 2017.

WANG, C.; WANG, G.; WANG, Y.; RAFIQUE, R.; MA, L.; HU, L.; LUO, Y. Fire alters vegetation and soil microbial community in Alpine Meadow. **Land Degradation & Development**, v. 27, n. 5, p. 1379–1390, 20 jul. 2016. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/ldr.2367>>.

WANG, L.; ZHU, H.; LIN, A.; ZOU, L.; QIN, W.; DU, Q. Evaluation of the latest MODIS GPP products across multiple biomes using global eddy covariance flux data. **Remote Sensing**, v. 9, n. 5, 418, 29 abr. 2017.

WARD, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American Statistical Association**, v. 58, n. 301, p. 236–244, 1963. Disponível em: <<https://doi.org/10.1080/01621459.1963.10500845>>.

WATSON, J. E. M.; EVANS, T.; VENTER, O.; WILLIAMS, B.; TULLOCH, A.; STEWART, C.; THOMPSON, I.; RAY, J. C.; MURRAY, K.; SALAZAR, A.; MCALPINE, C.; POTAPOV, P.; WALSTON, J.; ROBINSON, J. G.; PAINTER, M.; WILKIE, D.; FILARDI, C.; LAURANCE, W. F.; HOUGHTON, R. A.; MAXWELL, S.; GRANTHAM, H.; SAMPER, C.; WANG, S.; LAESTADIUS, L.; RUNTING, R. K.; SILVA-CHÁVEZ, G. A.; ERVIN, J.; LINDENMAYER, D. **The exceptional value of intact forest ecosystems** *Nature Ecology and Evolution*. Nature Publishing Group, 26 fev. 2018. Disponível em: <<https://www.nature.com/articles/s41559-018-0490-x>>. Acesso em: 13 set. 2021.

WENZEL, F. **Depois da madeira vem o gado: O desmatamento em Santo Antônio do Matupi**. Disponível em: <<https://idesam.org/conteudo/imprensa/depois-da-madeira-vem-o-gado-o-desmatamento-em-santo-antonio-do-matupi/>>.

WWF. **Estradas** | **WWF Brasil**. Disponível em: <https://www.wwf.org.br/natureza_brasileira/areas_prioritarias/amazonia1/ameacas_riscos_a_mazonia/infraestrutura_na_amazonia/estradas_na_amazonia/>. Acesso em: 13 mar. 2023.

YAN, H.; WANG, S.; HUETE, A.; SHUGART, H. H. Effects of light component and water stress on photosynthesis of amazon rainforests during the 2015/2016 El Niño drought. **Journal of Geophysical Research: Biogeosciences**, v. 124, n. 6, p. 1574–1590, 23 jun. 2019.

ZEMP, D. C.; SCHLEUSSNER, C.-F.; BARBOSA, H. M. J.; RAMMIG, A. Deforestation effects on Amazon forest resilience. **Geophysical Research Letters**, v. 44, n. 12, p. 6182–6190, 28 jun. 2017. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/2017GL072955>>. Acesso em: 13 set. 2021.

ZHANG, H.; HAGAN, D. F. T.; DALAGNOL, R.; LIU, Y. Forest canopy changes in the Southern Amazon during the 2019 fire season based on passive microwave and optical satellite observations. **Remote Sensing**, v. 13, n. 12, 2238, 8 jun. 2021a.

ZHANG, L.; TIAN, H.; SHI, H.; PAN, S.; QIN, X.; PAN, N.; DANGAL, S. R. S. Methane emissions from livestock in East Asia during 1961–2019. **Ecosystem Health and Sustainability**, v. 7, n. 1, 1918024, 2021b.

ZHANG, Y.; XIAO, X.; WU, X.; ZHOU, S.; ZHANG, G.; QIN, Y.; DONG, J. A global moderate resolution dataset of gross primary production of vegetation for 2000–2016. **Scientific Data**, v. 4, n. 1, 170165, 19 dez. 2017a.

ZHANG, Z.; FENG, Z.; ZHANG, H.; ZHAO, J.; YU, S.; DU, W. Spatial distribution of grassland fires at the regional scale based on the MODIS active fire products. **International Journal of Wildland Fire**, v. 26, n. 3, 209, 2017b. Disponível em: <<http://www.publish.csiro.au/?paper=WF16026>>.

ZHAO, M.; HEINSCH, F. A.; NEMANI, R. R.; RUNNING, S. W. Improvements of the MODIS terrestrial gross and net primary production global data set. **Remote Sensing of Environment**, v. 95, n. 2, p. 164–176, mar. 2005.



Article

Changes in Carbon Dioxide Balance Associated with Land Use and Land Cover in Brazilian Legal Amazon Based on Remotely Sensed Imagery

Patrícia Monique Crivelari-Costa ¹, Mendelson Lima ², Newton La Scala Jr. ³, Fernando Saragosa Rossi ⁴, João Lucas Della-Silva ¹, Ricardo Dalagnol ^{5,6}, Paulo Eduardo Teodoro ⁷, Larissa Pereira Ribeiro Teodoro ⁷, Gabriel de Oliveira ⁸, José Francisco de Oliveira Junior ⁹ and Carlos Antonio da Silva Junior ^{4,*}

¹ Rede Bionorte Graduate Program, State University of Mato Grosso (UNEMAT), Sinop 78550-000, Mato Grosso, Brazil

² Department of Biology, State University of Mato Grosso (UNEMAT), Alta Floresta 78580-000, Mato Grosso, Brazil

³ Department of Exact Sciences, School of Agricultural and Veterinarian Sciences, São Paulo State University (UNESP), Jaboticabal 14884-900, São Paulo, Brazil

⁴ Department of Geography, State University of Mato Grosso (UNEMAT), Sinop 78550-000, Mato Grosso, Brazil

⁵ Center for Tropical Research, Institute of the Environment and Sustainability, University of California Los Angeles (UCLA), Los Angeles, CA 90095, USA

⁶ NASA-Jet Propulsion Laboratory, California Institute of Technology, Pasadena, CA 91109, USA

⁷ Department of Agronomy, Federal University of Mato Grosso do Sul (UFMS), Chapadão do Sul 79560-000, Mato Grosso do Sul, Brazil; paulo.teodoro@ufms.br (P.E.T.)

⁸ Department of Earth Sciences, University of South Alabama, Mobile, AL 36688, USA

⁹ Institute of Atmospheric Sciences, Federal University of Alagoas (UFAL), Maceió 57072-970, Alagoas, Brazil

* Correspondence: carlosjr@unemat.br



Citation: Crivelari-Costa, P.M.; Lima, M.; La Scala Jr., N.; Rossi, F.S.; Della-Silva, J.L.; Dalagnol, R.; Teodoro, P.E.; Teodoro, L.P.R.; Oliveira, G.d.; Junior, J.F.d.O.; et al. Changes in Carbon Dioxide Balance Associated with Land Use and Land Cover in Brazilian Legal Amazon Based on Remotely Sensed Imagery. *Remote Sens.* **2023**, *15*, 2780. <https://doi.org/10.3390/rs15112780>

Academic Editor: Huaqiang Du

Received: 17 April 2023

Revised: 15 May 2023

Accepted: 22 May 2023

Published: 26 May 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: The Amazon region comprises the largest tropical forest on the planet and is responsible for absorbing huge amounts of CO₂ from the atmosphere. However, changes in land use and cover have contributed to an increase in greenhouse gas emissions, especially CO₂, and in endangered indigenous lands and protected areas in the region. The objective of this study was to detect changes in CO₂ emissions and removals associated with land use and land cover changes in the Brazilian Legal Amazon (BLA) through the analysis of multispectral satellite images from 2009 to 2019. The Gross Primary Production (GPP) and CO₂Flux variables were estimated by the MODIS sensor onboard Terra and Aqua satellite, representing carbon absorption by vegetation during the photosynthesis process. Atmospheric CO₂ concentration was estimated from the GOSAT satellite. The variables GPP and CO₂Flux showed the effective flux of carbon in the BLA to atmosphere, which were weakly correlated with precipitation ($r = 0.191$ and 0.133). The forest absorbed 211.05 TgC annually but, due to its partial conversion to other land uses, the loss of 135,922.34 km² of forest area resulted in 5.82 TgC less carbon being absorbed. Pasture and agriculture, which comprise the main land conversions, increased by 100,340.39 km² and absorbed 1.32 and 3.19 TgC less, and emitted close to twice more, than forest in these areas. Atmospheric CO₂ concentrations increased from 2.2 to 2.8 ppm annually in BLA, with hotspots observed in the southeast Amazonia, and CO₂ capture by GPP showed an increase over the years, mainly after 2013, in the north and west of the BLA. This study brings to light the carbon dynamics, by GPP and CO₂Flux models, as related to the land use and land cover in one of the biggest world carbon reservoirs, the Amazon, which is also important to fulfillment of international agreements signed by Brazil to reduce greenhouse gas emissions and for biodiversity conservation and other ecosystem services in the region.

Keywords: carbon dioxide flux; gross primary production; google earth engine; MODIS; GOSAT

1. Introduction

Intact forest ecosystems play a key role in increasing resilience to climate change, and conserving biodiversity [1,2]. The Brazilian Legal Amazon, delimited according to Art. 2 of Complementary Law No. 124, of 3 January 2007 [3], has a total area of 5.02 M km², corresponding to 58.9% of the Brazilian territory [4]. This area is responsible for holding the Earth's greatest biodiversity and above ground biomass, also accounting for one of the largest sources of mineral and biological resources [5–7].

Among the ecosystem services provided is the removal of carbon through CO₂ from the atmosphere, via capture and storage by increase in gross primary production (GPP) [8–10]. A total forest sink of 2.4 ± 0.4 Pg C year⁻¹ was estimated globally, and 262.1 Pg C of this was stocked in tropical America [11]. The GPP relates to carbon dioxide absorption during the photosynthesis process [12–14]. The analysis of anomalies in the GPP values determines the impact of changes in both carbon absorption and emissions [15]. It is possible and necessary to accurately estimate their temporal and spatial variations to understand several ecosystem functions in response to climate and land use and land cover changes [16,17]. These processes play an important role in the carbon balance between the atmosphere and the biosphere [6,18], as well as in the modifications in response to climate change [19–21]. These modifications are mainly related to forest loss, induced by deforestation, which contributes to greenhouse gas emissions, thus worsening global warming [22–24].

Indigenous lands (IL), areas destined for the indigenous population, and protected areas (PA), areas for environmental conservation, in the BLA accounted for 43% of the total land area and covered about half of the total forest area in the region [2]; they are important in conserving the standing forest, biodiversity, and in mitigating the climate in the Brazilian Legal Amazon, as they act as “shields” against deforestation [2,25,26]. However, forest conservation in IL/PA has been facing increasing threats from weak environmental laws and regulations, changes in government priorities and massive economic development [24,27,28]. In the Brazilian Legal Amazon (BLA), 75% of deforestation has occurred in large swathes along highways, most of them close to IIs and PAs, inducing forest losses due to different land use and land cover changes [28,29]. An example is the paving of the Belém-Brasília (BR-010) and Cuiabá-Porto Velho (BR-364) highways that originated the so-called “arc of deforestation” [30,31].

Increased carbon emissions, land use and land cover changes, and anthropogenic pressure are the main drivers in the degradation of tropical forests, such as the Amazon, which have led to severe losses of carbon sinks [22,32,33]. Land use and land cover changes caused by anthropogenic activities have substantially altered carbon cycling, contributing to the increase in atmospheric CO₂ concentration (XCO₂), among other greenhouse gases, which is the main cause of global warming and climate change [34]. Land use change in tropical climates accounted for 1.1 ± 0.7 Pg C of terrestrial carbon emissions between 2000–2007 [11]. The historical assessment of land use and land cover changes is important for the management of natural resources and the development of sustainable policies, as it gives insights into the interaction between the environment and humans in a given region, thus preventing further environmental degradation in several aspects [35–37].

Remote sensing techniques are often used to better understand land use and land cover changes, as they reduce the cost and time necessary to detect environmental degradation [38–40] and climate and carbon fluxes, as extensively covered in the recent literature [18,20,21,34,41–43]. Remote sensing has recently been applied to updating the boundaries between the Brazilian Cerrado-Amazon biomes, due to land use and land cover changes, by using vegetation indices such as Gross Primary Productivity (GPP) and carbon dioxide fluxes (CO₂Flux), allowing the development of public policies to curb deforestation and degradation by anthropogenic activities [44]. Remote sensing has also been crucial in helping to uncover the vital role and substantial progress made by IL and PA in conserving the Amazon, and the risks from the recent weakening of forest policies in Brazil [2,45].

Studies point out that 40% deforestation in the Amazon would lead to a decrease in rainfall and a longer dry season. They also highlight that 20–25% deforestation would be the tipping point for the Amazonian system to shift to a non-forest ecosystem in most of the Amazon [35,36,46,47]. In this regard, it is expected that changes in CO₂ emissions and removals induced by land use and land cover changes in the Brazilian Legal Amazon have intensified in recent years and could be identified and quantified through MODIS images and physically based models. Here, we investigate the relationship between land use and land cover changes, GPP, CO₂Flux, XCO₂ and precipitation in the Brazilian Legal Amazon from 2009 to 2019. We believe that the investigation into the loss or gain in the carbon absorption capacity of these areas could facilitate more environmentally friendly and sustainable decisions, in order to preserve BLA and carbon pools in the region.

2. Materials and Methods

2.1. Study Area

The Brazilian Legal Amazon [3] comprises the States of Acre, Amapá, Amazonas, Mato Grosso, Rondônia, Roraima, Tocantins, Pará, and part of the State of Maranhão, located west of the 44th meridian (Figure 1). It has an area of 5.02 M km², corresponding to 58.9% of the Brazilian territory [4]. The BLA contains three of the most important biomes in Brazil, the Amazon, Cerrado and Pantanal [4,48,49]. While the Amazon is covered mainly by tropical rainforests, Cerrado is a biome covered by a range of savannah-type vegetation, and Pantanal is covered by a mosaic of grasslands, flooded grasslands, wooded savanna, and riparian forests.

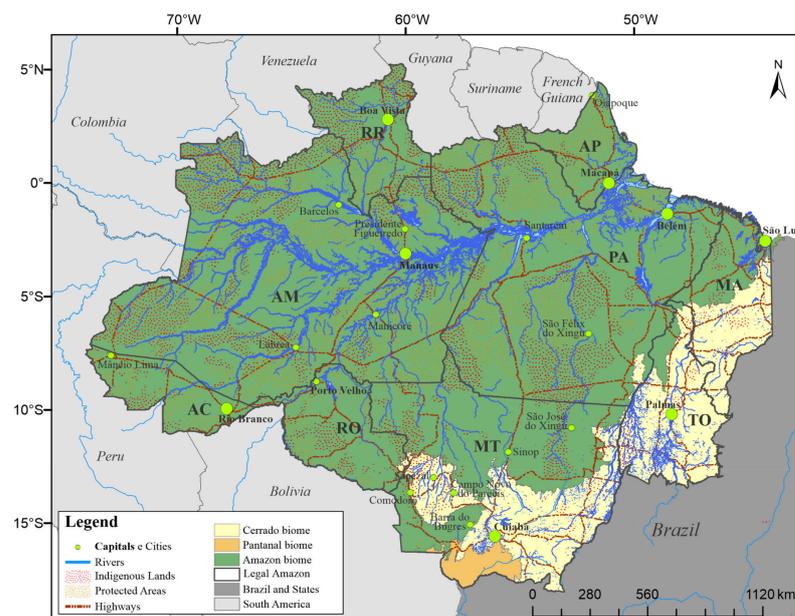


Figure 1. Brazilian Legal Amazon and its main biomes [4,49,50]. States of Acre (AC), Amapá (AP), Amazonas (AM), Mato Grosso (MT), Maranhão (MA), Rondônia (RO), Roraima (RR), Tocantins (TO) and Pará (PA).

The predominant climate in the BLA is type “A”, or tropical, in which the average monthly temperature is never below 18 °C [51]. Three major types of climate are highlighted: the “Af” type (hot and rainy throughout the year), located in the northwest of the Brazilian Legal Amazon, the “Am” (humid or sub-humid tropical climate), from the northeast to the south, marking the transition between humid tropical climates and those with a long dry season in the southern flank, and the “Aw” type (tropical climate, with dry winter), between the south and east, predominantly in the States of Mato Grosso, Rondônia, Tocantins and Maranhão [52].

2.2. Data

2.2.1. Land Use and Land Cover Data

In order to quantify the temporal and spatial variations in land use and land cover in the BLA, we obtained the MCD12Q1 version 06 product from the Moderate Resolution Imaging Spectroradiometer (MODIS) sensor on board the Terra and Aqua satellites [53]. This product was chosen because of its high accuracy over time and its public availability [41,54–57]. The algorithm that processes the product (V006 Global 500 m Land Cover Type Product) is based on supervised decision tree classifications of MODIS Terra and Aqua reflectance data and provides global land cover types at yearly intervals in 500 m of spatial resolution [53]. It contains five types of land cover classification, which describe surface properties, in sequence, derived from the International Geosphere–Biosphere Programme (IGBP), University of Maryland (UMD), Leaf Area Index (LAI), BIOME–Biogeochemical Cycles (BGC), and Plant Functional Types (PFT) classification schemes. The Type 1 classification scheme, from IGBP, was used (Table 1) between 2009 and 2019, as it is the most complete classification considering the purposes of this study [41,53,56]. To avoid mixing up atmospheric carbon estimates from land cover and use classes, we did not use the ENF, DNF, OS, BN, CS and NVM classes, since they were smaller than 1000 km² for all years [54].

Table 1. Type 1 classification of MCD12Q1 product ¹.

Class	Color	Acronym	Description
1	05450a	ENF	Evergreen Needleleaf Forests: dominated by evergreen conifer trees (canopy >2 m). Tree cover >60%.
2	086a10	EBF	Evergreen Broadleaf Forests: dominated by evergreen broadleaf and palmate trees (canopy >2 m). Tree cover >60%.
3	54a708	DNF	Deciduous Needleleaf Forests: dominated by deciduous needleleaf (larch) trees (canopy >2 m). Tree cover >60%.
4	78d203	DBF	Deciduous Broadleaf Forests: dominated by deciduous broadleaf trees (canopy >2 m). Tree cover >60%.
5	009900	MF	Mixed Forests: dominated by neither deciduous nor evergreen (40–60% of each) tree type (canopy >2 m). Tree cover >60%.
6	c6b044	CS	Closed Shrublands: dominated by woody perennials (1–2 m height) >60% cover.
7	dcd159	OS	Open Shrublands: dominated by woody perennials (1–2 m height) 10–60% cover.
8	dade48	WSV	Woody Savannas: tree cover 30–60% (canopy >2 m).
9	fbff13	SV	Savannas: tree cover 10–30% (canopy >2 m).
10	b6ff05	GL	Grasslands: dominated by herbaceous annuals (<2 m).
11	27ff87	PW	Permanent Wetlands: permanently inundated lands with 30–60% water cover and >10% vegetated cover.
12	c24f44	CL	Croplands: at least 60% of area is cultivated cropland.
13	a5a5a5	UBL	Urban and Built-up Lands: at least 30% impervious surface area including building materials, asphalt and vehicles.
14	ff6d4c	NVM	Cropland/Natural Vegetation Mosaics: mosaics of small-scale cultivation 40–60% with natural tree, shrub, or herbaceous vegetation.
15	69fff8	PSI	Permanent Snow and Ice: at least 60% of area is covered by snow and ice for at least 10 months of the year.
16	f9ffa4	BN	Barren: at least 60% of area is non-vegetated barren (sand, rock, soil) areas with less than 10% vegetation.
17	1c0dff	WB	Water Bodies: at least 60% of area is covered by permanent water bodies.

¹ MCD12Q1 product [53].

The parameters of time and space for each type of land use and land cover were calculated using JavaScript language as input in the Google Earth Engine platform [58].

For analysis of the carbon estimates, 10 points were randomly selected, representative of each class of land use and land cover in the BLA and for each year, so that it was ensured that a given point was always considered in the same class for all the years studied. This was needed in order to verify if the emissions induced by land use and land cover changes in the BLA surrounding these selected points were impacting the class. These points were collected by the Google Earth Engine platform, by using the “Inspector” tab. The points were approximated from 1 to 2 km per pixel [57].

2.2.2. Gross Primary Production (GPP)

To analyze the GPP across the land cover and use classes, we obtained the MYD17A2H product, which is a cumulative composite of the GPP values based on the efficiency of use of solar radiation by vegetation [14,59]. The MODIS algorithm converts (via a conversion efficiency look-up table) the absorbed photosynthetically active radiation (related to the total amount of leaf area) to carbon uptake [8,60]. The MYD17A2H MODIS 8-day cumulative GPP product (2009–2019; 11 years total) was acquired using JavaScript language as input in the Google Earth Engine platform [58]. The GPP values were converted from the cumulative value every 8 days to annual median values ($\text{g C m}^{-2} \text{ year}^{-1}$).

2.2.3. Carbon Dioxide Flux (CO_2Flux)

To estimate annual forests’ carbon dioxide fluxes ($\mu\text{mol m}^{-2} \text{ s}^{-1}$), we employed the carbon dioxide fluxes (CO_2Flux). This is a remote sensing-based empirical model based on the Normalized Difference Vegetation Index (NDVI) (Equation (1)) and the scaled Photochemical Reflectance Index (sPRI) (Equation (2)) vegetation indices. Negative values represent a CO_2 sink, while positive values represent a CO_2 source [18,34,42,61]. While NDVI reveals the vigor of photosynthetically active vegetation, in which it may be able to absorb carbon [34,42], the sPRI estimates the carotenoid pigments of the leaves, indicating their rate of carbon dioxide storage [41]. For the calculation of NDVI, spectral bands 1 (620–670 nm) for red and 2 (841–876 nm) for NIR were used, based on the product MOD09A1 (Equation (1)). The bands used from the MOD09A1 product have a spatial and temporal resolution of 500 m, 1 to 2 days, respectively [62]. To estimate the sPRI, spectral bands 3 (459–479 nm), for blue (B), and 4 (545–565 nm), for green (G), of the MOD09A1 product were used:

$$\text{NDVI} = \frac{\text{NIR} - \text{R}}{\text{NIR} + \text{R}} \quad (1)$$

$$\text{sPRI} = \left[\left(\frac{\text{B} - \text{G}}{\text{B} + \text{G}} \right) + 1 \right] / 2, \quad (2)$$

The CO_2Flux values ($\mu\text{mol m}^{-2} \text{ s}^{-1}$) were estimated annually by taking the annual median of the time series (Equation (3)). The factors used in the equation were calibrated based on the Eddy Covariance method in micrometeorological towers [34,42,61].

$$\text{CO}_2\text{Flux} = 13.63 - 66.207 (\text{NDVI} \times \text{sPRI}), \quad (3)$$

The annual median values were calculated between 2009 and 2019 using JavaScript language as input in the Google Earth Engine platform [58].

2.2.4. Atmospheric CO_2 Concentration (XCO_2)

The atmospheric CO_2 concentration (XCO_2) data were acquired from the Greenhouse Gases Observing Satellite (GOSAT) in order to evaluate the spatial and temporal behavior of XCO_2 over the 11 years (April 2009 to December 2019) in the BLA. The GOSAT calculates the average XCO_2 in the path of sunlight reflected by the surface [63,64]. The XCO_2 did not account for all land use and land cover classes, because it has a spatial resolution of 2.5° , or 278 km, at the equator, making it impossible to be detected by most classes [64].

2.2.5. Precipitation Data

To identify the patterns of precipitation from 2009 to 2019 in the different land use and land cover classes of the BLA, we used the English Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) data at 0.05° (± 5.3 km) spatial resolution and daily temporal resolution [43]. This presents satisfactory data for the spatiotemporal evaluation of regional precipitation in the Amazon, mainly because this region lacks data from in situ meteorological stations [15,43]. The annual sum values were calculated between 2009 and 2019.

2.3. Analysis

2.3.1. Land Use and Cover Change from 2009 to 2019

As a first step in understanding the carbon fluxes in the region, we analyzed the changes in the land cover and use classes across time from 2009 to 2019. We calculated the area occupied by each class in each year and determined the classes with highest area change.

2.3.2. Spatial Clustering of Atmospheric Carbon

The spatial and temporal evaluation of XCO₂, hotspots were analyzed using the Getis-Ord method [65]:

$$G_i = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\left[\frac{n \sum_{j=1}^n w_{i,j}^2 - (\sum_{j=0}^n w_{i,j})^2}{n-1} \right]}} \quad (4)$$

where G_i is the spatial dependence of incident i on all events n ; x_j is the magnitude of variable X at incident location j in observations (n) (j can be equal to i); and w_{ij} is the weight value between event i and j representing the spatial interrelationship.

The G_i statistic identifies significant spatial groupings of high (hotspots) or low (coldspots) values in the observations, and was developed for data sets in which there is no global spatial autocorrelation [65]. Hotspot analysis was performed in ArcGIS version 10.8 [66], and points were transformed to raster to provide a better visualization.

2.3.3. Shapiro-Wilk Normality Test

The CO₂Flux, XCO₂ and GPP datasets comprising 11 years (2009 to 2019) from 10 land cover and use classes (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL and WB) were subjected to the Shapiro-Wilk normality test, with the “RVAideMemoire” package in R [67], which allows analysis of the normality of values within a group, thus verifying whether the data is parametrically distributed with greater assertiveness [68].

A Shapiro-Wilk normality test without considering groups was also performed; however, not considering groups for larger samples of data can introduce errors and the RVAideMemoire::byf.shapiro() function can help to verify this. This function is an excellent choice for examining questions about normality by breaking factor-type object variables [69].

To allow a comparative view between the three variables (GPP, CO₂Flux and Rainfall) and complement the normality test, a histogram was generated. This presents distribution and frequency in relation to the center [69].

2.3.4. Variability of Carbon Fluxes in between Land Cover and Use Classes

To compare how carbon fluxes varied between the different land cover and use classes, we employed the non-parametric one-way Anova Kruskal-Wallis test. This test ranks the values, and groups with different distributions can be compared based on their medians [70,71]. The Kruskal-Wallis test was used to identify which parameters (land use and land cover classes or years) showed significant differences between the variables (GPP,

CO₂Flux and Rainfall) across the BLA [70,72]. The magnitude of changes was calculated by the percentage difference between the medians [70,71].

To identify in which groups these observed differences occurred, a Dunn post-hoc test was performed [70,72], with adjustment of the p -value by the Bonferroni method, an adjustment for multiple comparisons. The Bonferroni method is more conservative and guarantees the difference between these groups. For comparisons between groups with non-parametric data, the “rstatix” package in R was used [67]. Boxplots and scatterplots showing the variability of GPP, CO₂Flux and Rainfall amongst the 10-land use and land cover classes (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL and WB) were also produced. These analyzes were performed in R software using the GGEBiplotGUI package [67].

2.3.5. Cluster Analysis

To evaluate the affinities between land use and land cover and carbon emission/absorption and precipitation variables, we employed a cluster analysis based on the principal components and dendrogram methods [73]. The cluster analysis is based on unsupervised learning, in which the data are segmented into groups based on an exploratory analysis, in case of absence of a dependent variable, or doubts about it. In this way, cluster performs segmentation in the dataset through its attributes, organizing and facilitating visualization by grouping variables with similarities. It also helps in the detection of anomalies or outliers. Groups of clusters that minimize dissimilarity or minimize total sums of squares within groups are also known as Sum of Squared Deviation (SQD) [74]. At each step of the procedure, the groups were formed in such a way that the resulting solution has the smallest SQD within the groups. The union of all possible group pairs was considered. The two groups that resulted in a smaller increase in SQD were grouped to form a single group that brings together all subjects [75,76].

Clusters were generated using scaled GPP, CO₂Flux and Rainfall data for each use and land cover class between 2009 and 2019. For this, the Euclidean distance and Ward’s hierarchical method were used [74–76]:

$$d_e = \left[\sum_{j=1}^n (P_{p,j} - P_{k,j})^2 \right]^{\frac{1}{2}}, \quad (5)$$

where d_e is the Euclidean distance, and P_p and P_k are the variables j of subjects p and k .

Principal component analysis was also performed to examine whether the variables GPP, CO₂Flux and Rainfall, derived from remotely sensed data, could help characterize different land use and land cover in the BLA [73,77].

2.3.6. Trend Analysis

To identify years showing a trend over the time series (2009–2019) for each variable, we employed the Mann Kendall (MK) test [78,79] and the Pettitt test [80]. MK identifies whether time series values tend to increase or decrease over time, or whether the central value in the distribution of time series data changes over time. The Pettitt test shows when this trend occurred or confirms the stationarity of the historical series. This non-parametric test uses a version of the Mann-Whitney test, from which it is verified whether two samples X_1, \dots, X_t and X_{t+1}, \dots, X_T fit to the same population [80]. The $U_{t,T}$ statistic counted the number of times that a member of the first sample is greater than the member of the second, according to Equation (6). $U_{t,T}$ is calculated for the values of $1 < t < T$, and $k(t)$ is given by Equation (7).

$$U_{t,T} = U_{t-1,T} + \sum_{j=1}^T \text{sgn}(X_i - X_j), \quad (6)$$

$$k(t) = \text{MAX}_{1 \leq t \leq T} |U_{t,T}|, \quad (7)$$

where $\text{sgn}(x) = 1$ for $x > 0$; $\text{sgn}(x) = 0$ for $x = 0$; and $\text{sgn}(x) = -1$ for $x < 0$.

The Pettitt test locates the point at which an abrupt change occurred in the historical series, the t where the maximum of $k(t)$ occurs, resulting in K_{crit} , or critical values (Equation (8)), in the mean of a temporal series. Its significance was calculated by Equation (9).

$$K_{crit} = \pm \sqrt{\frac{-\ln\left(\frac{p}{2}\right)(T^3 + T^2)}{6}}, \quad (8)$$

$$p - value \cong 2exp\left\{\frac{-6k(t)^2}{(T^3 + T^2)}\right\}, \quad (9)$$

For the application of the Mann-Kendall and Pettitt tests, the “trend” and “ManKendall” packages were used in the R version 4.1.2 [67].

3. Results

3.1. Land Use and Land Cover Changes

The nomenclatures of the land use and land cover classes can be found at the bottom of Tables 1 and 2. The greatest extensions in area were observed for the classes EBF, SV, GL, WSV, WB, CL, PW, DBF, UBL and MF, from 3.37 M to 1.55 K km², respectively, while ENF, DNF, OS and BN classes were smaller than 200 km², and CS and NVM, were smaller than 1000 km². The PSI class was not observed (Table 2, Figure S1).

Table 2. Area, in km², of the land use and land cover classes of the BLA between 2009 to 2019.

Classes	ENF ¹	EBF	DNF	DBF	MF	CS	OS	WSV
2009	126.49	3,374,351.77	0.74	9370.81	2685.39	313.90	170.61	219,487.50
2010	110.76	3,363,598.69	0.00	10,976.39	2837.62	320.71	100.80	223,691.17
2011	114.47	3,356,746.45	0.00	11,235.69	2671.78	332.30	64.89	226,820.70
2012	119.11	3,351,448.68	0.00	12,161.83	2525.68	383.75	59.83	225,836.89
2013	132.59	3,346,877.56	0.00	12,592.50	2292.61	419.95	60.18	225,740.05
2014	141.44	3,341,805.65	0.00	13,785.02	2265.73	470.68	65.79	222,678.17
2015	144.93	3,332,142.23	0.00	15,043.02	2275.90	525.03	86.63	218,875.11
2016	143.43	3,320,505.98	0.00	15,357.38	2206.02	728.91	102.35	218,150.23
2017	157.83	3,318,989.15	0.24	16,228.36	2122.46	830.99	98.89	212,146.05
2018	148.00	3,311,486.93	0.00	15,606.63	1571.92	883.70	72.94	217,815.19
2019	122.77	3,307,899.08	0.00	16,282.29	1554.08	823.63	59.67	219,497.52
Minimum	110.76	3,307,899.08	0.24	9370.81	1554.08	313.90	59.67	212,146.05
Maximum	157.83	3,374,351.77	0.74	16,282.29	2837.62	883.70	170.61	226,820.70
Mean	132.89	3,338,713.83	0.09	13,512.72	2273.56	548.50	85.69	220,976.23
Classes	SV	GL	PW	CL	UBL	NVM	BN	WB
2009	814,410.32	427,688.15	42,969.10	46,468.92	3214.24	760.86	118.81	76,486.03
2010	814,458.43	430,814.48	43,318.25	47,845.75	3218.21	752.73	119.44	76,460.22
2011	820,451.11	424,921.60	44,032.14	50,617.98	3222.43	775.05	114.60	76,502.45
2012	828,404.93	419,508.25	44,750.54	52,640.53	3225.15	807.99	120.01	76,630.49
2013	831,246.14	418,879.58	45,302.60	54,131.14	3227.63	837.67	121.21	76,762.25
2014	829,377.20	425,725.68	45,899.51	55,250.24	3232.08	884.83	126.88	76,914.74
2015	825,109.87	440,198.42	46,546.19	56,517.91	3234.31	892.63	139.62	76,891.86
2016	821,453.22	454,674.01	47,346.18	56,951.16	3236.53	915.08	166.13	76,687.03
2017	814,680.05	466,125.38	46,820.45	59,371.91	3241.23	867.62	177.82	76,765.22
2018	792,856.33	489,266.49	47,711.84	60,107.64	3245.43	798.85	160.64	76,891.15
2019	777,734.68	504,234.83	47,931.70	61,454.07	3249.64	668.03	142.10	76,969.55
Minimum	777,734.68	418,879.58	42,969.10	46,468.92	3214.24	668.03	114.60	76,460.22
Maximum	831,246.14	504,234.83	47,931.70	61,454.07	3249.64	915.08	177.82	76,969.55
Mean	815,471.12	445,639.72	45,693.50	54,668.84	3231.53	814.67	137.02	76,723.73

¹ Evergreen Needleleaf Forests (ENF); Evergreen Broadleaf Forests (EBF); Deciduous Needleleaf Forests (DNF); Deciduous Broadleaf Forests (DBF); Mixed Forests (MF); Closed Shrublands (CS); Open Shrublands (OS); Woody Savannas (WSV); Savannas (SV); Grasslands (GL); Permanent Wetlands (PW); Croplands (CL); Urban and Built-up Lands (UBL); Natural Vegetation Mosaics (NVM); Barren (BN); and Water Bodies (WB).

From 2009 to 2019, there were increases in the areas of DBF (6911.48 km²), CS (509.74 km²), WSV (10.02 km²), GL (76,546.68 km²), PW (4962.60 km²), CL (14,985.15 km²), UBL (35.40 km²), BN (23.29 km²) and WB (483.52 km²) and, on the other hand, decreases in the areas of ENF (3.72 km²), EBF (66,452.69 km²), MF (1131.31 km²), OS (110.94 km²), SV (36,675.64 km²) and NVM (92.83 km²).

The EBF had the largest area (3.34 M km²), observed in the center, east and north of the BLA. It is also that which suffered the majority of the losses over the study period, of 66,452.69 km². Considering the total study area, the EBF represented 67.28% in 2009 and dropped to 65.95% in 2019. This evidences a reduction of ~2%, as an annual mean of 6645.27 km² in land use and land changes (Figure 1, Table 2).

Larger areas of SV, GL and WSV were observed in the northeast to south of BLA, representing the second, third and fourth largest extensions, close to each other. These classes were observed from the northeast, near São Luís—MA, to the south of the BLA, as well as in the region of Boa Vista—RO (Figure 1). The DBF and MF classes were observed closer to the SV, GL and WSV classes. In greater concentration, the DBF was observed in the south of Mato Grosso state (MT) and in the central part of Maranhão, and MF in the southeast of Mato Grosso and Pará. The CL was the sixth largest in area and was observed mainly in the southern flank of the BLA (Figures 1 and 2).

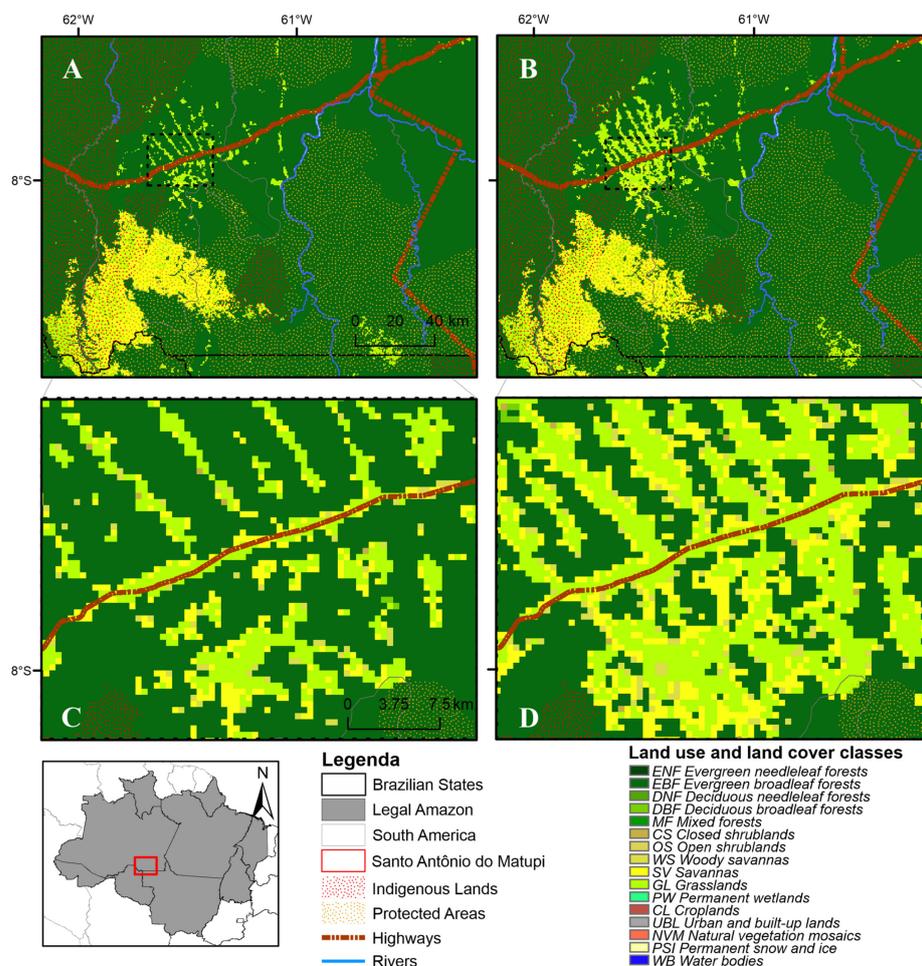


Figure 2. Land use and land cover changes in the district of Santo Antônio do Matupi, municipality of Manicoré—AM, for 2009 (A) with its expanded version (C), and for 2019 (B) with its expanded version (D).

The SV was observed close to the WB, the fifth largest class, and federal highways throughout the studied area, while a strong highlight for the GL class was observed in

the middle east and in the state of Roraima. The greatest representation of this class was in the Cerrado and Pantanal biomes, especially in the transitions to the Amazon biome (Figures 1 and 2).

Decrease for the SV and WSV areas was also observed, of 53,511.46 km² from 2013 to 2019 and 14,674.65 km² from 2011 to 2017, respectively, while an increase was observed for the GL class after 2013 and until 2019, of 85,355.24 km² (Table 2).

The CS and OS classes were observed as adjacent to the other classes, with some scattered points to the north, east and south regions of the BLA. The NVM class was strongly related to the CL class, so that both were observed in greater numbers from the northeast to the south (Figure S1). The BN class was observed in the east of the BLA, close to the Tocantins and Araguaia rivers (WB class), in regions where the sand was exposed, forming small beaches [4,50] (Figures 1 and 2). The PW class appeared to be related to the WB class, one adjacent to the other, and it was observed throughout the studied area in branched continuous formats, represented by the largest rivers in the region, such as the Amazon, Negro, Solimões, Araguaia and Tocantins (WB class) [4,81]. The UBL class was also observed throughout the studied area in small, scattered spots. The DNF class was observed in the northwest region of the BLA (Figure S1), north of the city of Barcelos—AM, at the southern intersection between the Serra do Aracá State Park and Amazonas National Forest PA [4,50]. These points were observed only in 2009 and 2017, and represented a decrease of 0.50 km² in the area (Figures 1 and 2).

Figure 2 highlights the district of Santo Antônio do Matupi (state of Amazonas) comparing years 2009 (Figure 2A,C) and 2019 (Figure 2B,D). This is typical example of a larger land use and land cover change from forest to anthropized areas. The district of Santo Antônio do Matupi is located in the south of the State of Amazonas, bordering the States of Mato Grosso and Rondônia, close to the “Transamazônica 230” highway. As mentioned above, this site was especially chosen because it presented significant forest losses, mainly from EBF, and the increase in anthropized areas, the GL classes more intense around the “Transamazônica 230” highway. The district of Santo Antônio do Matupi is located north of the Campos Amazônicos National Park and the Aripuanã National Forest PA and south of the Campos de Manicoré Environmental PA and the Manicoré Biological Reserve [82].

Such land use change is close to the Iles Diahui, Pirahã, Sepoti, Tenterim Marmelos, and Tenterim do Igarapé Preto, which are also in zones of environmental, ecological, and social preservation [2]. However, Santo Antônio do Matupi is an important timber exploitation region. This fact was confirmed by Duarte et al. [83], who observed losses of primary forests in Santo Antônio do Matupi, with the most critical period of deforestation rates recorded between 2004 and 2018, when 63.28% of the deforested area was converted into pastures. In 2010, it was one of the ten highest contributing communities to the economy of Amazonas, in 2014 the fourth largest cattle producer in the State, and the largest producer of wood, with a herd increase of 800% and a deforested area of more than 676.5 km² [83,84].

3.2. Spatial Variability of Carbon

Higher GPP values were found in the western, central, and northern regions of the BLA, with averages between 40 and 44 gC m⁻², as can be seen mostly for the EBF class (Figures 4 and S1 and Table 2). The maximum values of GPP, represented by navy-blue color, were found in the northeast of the BLA, in the regions of the State of Amapá and northwest of Pará, near to the equator [4,50], with annual maximums between 80.55 gC m⁻² (2009) and 88.2 gC m⁻² (2015) (Figure S2).

Values close to zero were observed on the border from east to south of the studied area and in the State of Roraima. In the year 2016, a greater intensity of values and greater extension in relation to other years were observed, represented by the orange color in the Southeast and mostly related to the land use classes SV, GL and WSV. In addition, the MF, SV and WSV decreased in extension while GL, CL, UBL, PW and WB increased, with these

land use and land cover changes related to a decrease in the GPP values in the studied period (Figure S2, Table 2).

Lowest CO₂Flux values were found in the central and western regions of the BLA. Such values, often negative, were represented by the forest classes EBF, DBF, MF and WSV, with EBF class being the main one, due to its extension. In the center of the study area, higher carbon absorptions were observed, mainly in 2019, of $-8.35 \mu\text{mol m}^{-2} \text{s}^{-1}$ to the EBF class similar to observed by Rossi et al. [34] in 2017. The highest values of CO₂Flux were observed in the transition from northeast to south, where the SV, GL, CL, and PW classes are located (Figure S3).

The spatial distribution of XCO₂ hotspots was concentrated in the central and southeastern region of the BLA (Figure 3). As observed for GPP (Figure S2), in 2009 and 2016, the Southeast region displayed a large concentration of 99% confidence hotspots, frequent in most of the studied years. In the central-north regions of State of Mato Grosso, hotspots were observed in 2015 and 2016 and had higher XCO₂ spatial atmospheric patterns than 2017 and 2018 (Figure 3).

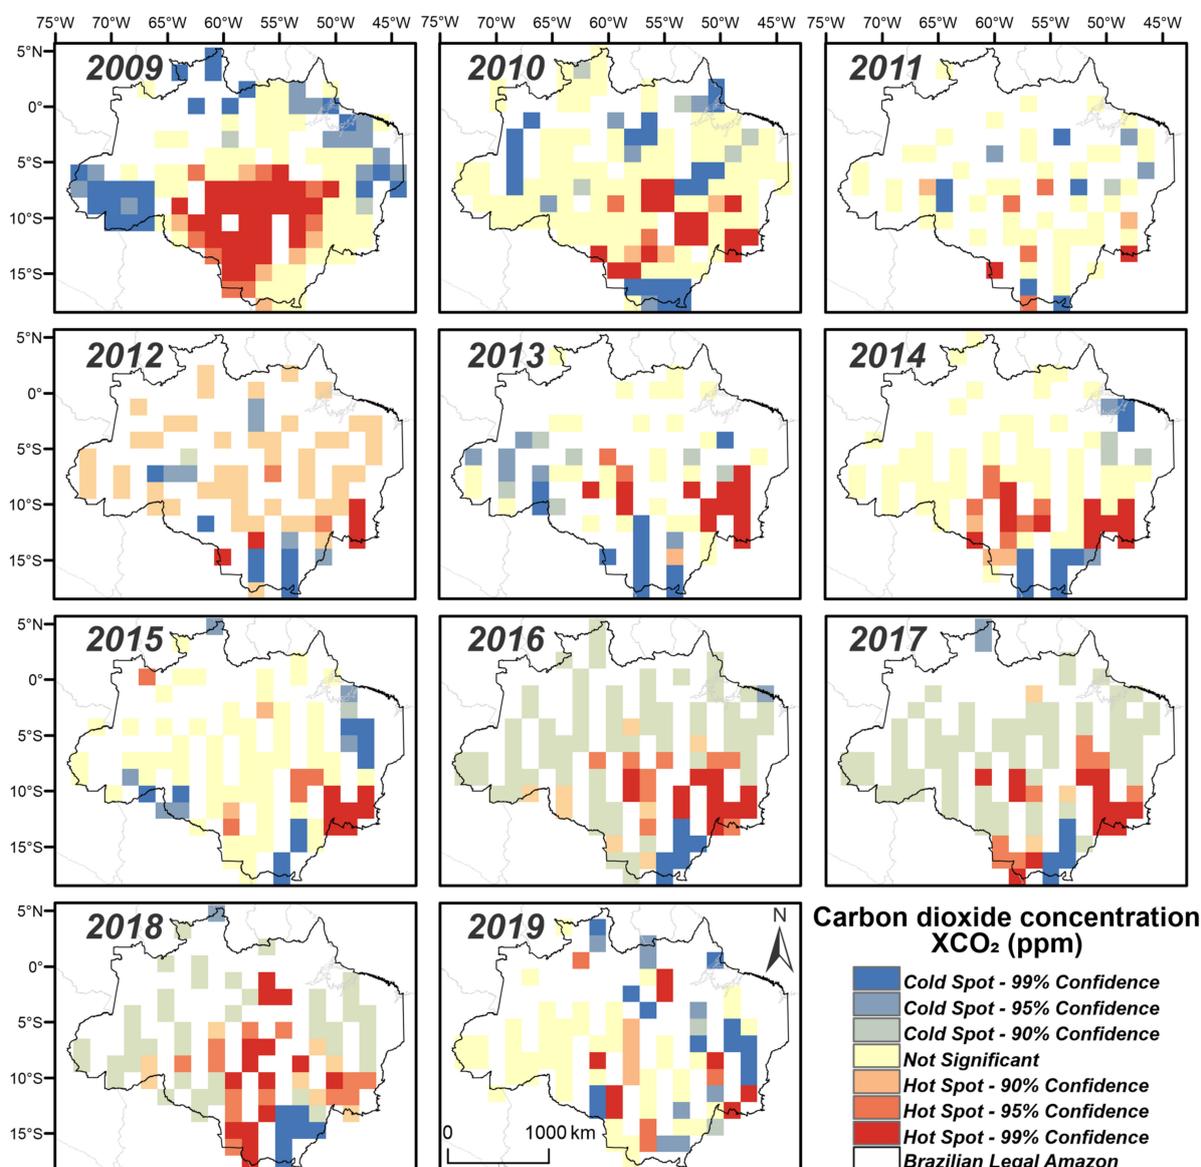


Figure 3. Hotspot for atmospheric CO₂ concentrations (XCO₂) retrieved from GOSAT data in the BLA between 2009 to 2019.

On the other hand, coldspots were mostly distributed from the north and west of the BLA, and in part to the south, compared with negative CO₂ flux and positive GPP. These represent the significant negative values that resulted in a more intense grouping of low values, in a typically forested area as EBF class. Coldspots were also observed from 2010 to 2018 in the southern region, with emphasis on the years 2016 to 2018, in which there was a large percentage of coldspots at a 90% confidence level, which contrasted with preceding years (Figure 3).

For all the years studied, the central, western, and northern parts of the BLA had higher rainfall, except for the extreme northern area, in Roraima. Annual maximums were observed in the Northwest for all years and in the Northeast for the years 2009 to 2013 and 2017 to 2019. The minimum precipitation was observed on the east to south flanks for 2015 to 2017. The lowest precipitation was in 2015 due to a severe drought event in Amazonia [13,40]. The maximum values of precipitation were found in the north, close to the Equator, except for 2014 to 2016 and 2019, for the State of Amapá (Figure S4).

3.3. Statistical Analysis

According to Table 3, the non-grouping demonstrated non-normal distribution for the variables, as they presented a *p*-value > 5% from the Shapiro-Wilk test [68]. However, the data were normal when grouped by year for GPP and Rainfall, and when grouped in classes for CO₂ Flux and Rainfall (precipitation). It was not possible to verify the normality of the grouping in classes for GPP, because WB and UBL data showed null values, as they do not represent vegetative classes [41].

Table 3. *p*-value of the multivariate Shapiro-Wilk normality test non-grouping and grouped by classes and years for the variables GPP, CO₂ Flux and Rainfall.

Variable	Grouped by Classes										
	Non-Grouping	EBF	DBF	MF	WSV	SV	GL	PW	CL	UBL	WB
GPP	0.000 ***	-	-	-	-	-	-	-	-	-	-
CO ₂ Flux	0.000 ***	0.000 ***	0.936	0.658	0.204	0.874	0.047 **	0.474	0.007 ***	0.692	0.464
Rainfall	0.000 ***	0.793	0.786	0.436	0.952	0.229	0.577	0.0794 *	0.695	0.117	0.424
Grouped by Year											
	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
GPP	0.483	0.406	0.439	0.390	0.506	0.567	0.470	0.493	0.478	0.421	0.398
CO ₂ Flux	0.004 ***	0.007 ***	0.005 ***	0.006 ***	0.000 ***	0.009 ***	0.005 ***	0.008 ***	0.008 ***	0.005 ***	0.006 ***
Rainfall	0.192	0.824	0.715	0.2067	0.007 ***	0.015 **	0.002 ***	0.006 ***	0.058 *	0.062 *	0.144

*, ** and ***: significant at 10, 5 and 1% probability by Shapiro-Wilk normality test. Evergreen Broadleaf Forests (EBF); Deciduous Broadleaf Forests (DBF); Mixed Forests (MF); Woody Savannas (WSV); Savannas (SV); Grasslands (GL); Permanent Wetlands (PW); Croplands (CL); Urban and Built-up Lands (UBL) and Water Bodies (WB).

The EBF, GL and CL represented the greatest variabilities for CO₂ Flux, and PW for Rainfall within the years 2013 to 2018. The Shapiro-Wilk grouped normality test indicates that statistics could be applied to normal data distribution to GPP or Rainfall over the years. The same occurred in the case of the Rainfall variable in different land use classes (Table 3).

Complementary to the Shapiro-Wilk normality test, the histogram showed the data distribution and in which position was its highest frequency. This was observed between 20 and 40 gC m⁻², for the GPP, from -1 to 2.5 μmol μmol m⁻² s⁻¹, for CO₂ Flux, and from 1600 to 2200 mm, for Rainfall variables. Based on the histogram, it was also possible to identify unexpected values and trends (Figure S5).

Since the multivariate Shapiro-Wilk normality test and the histogram (Table 3 and Figure S5) presented non-parametric data [69,71], we decided to apply the Kruskal-Wallis and Dunn tests to compare groups of classes. The boxplots grouped by classes and by years were performed (Figure 4). The median values of the classes and years groups are shown in Table S1.

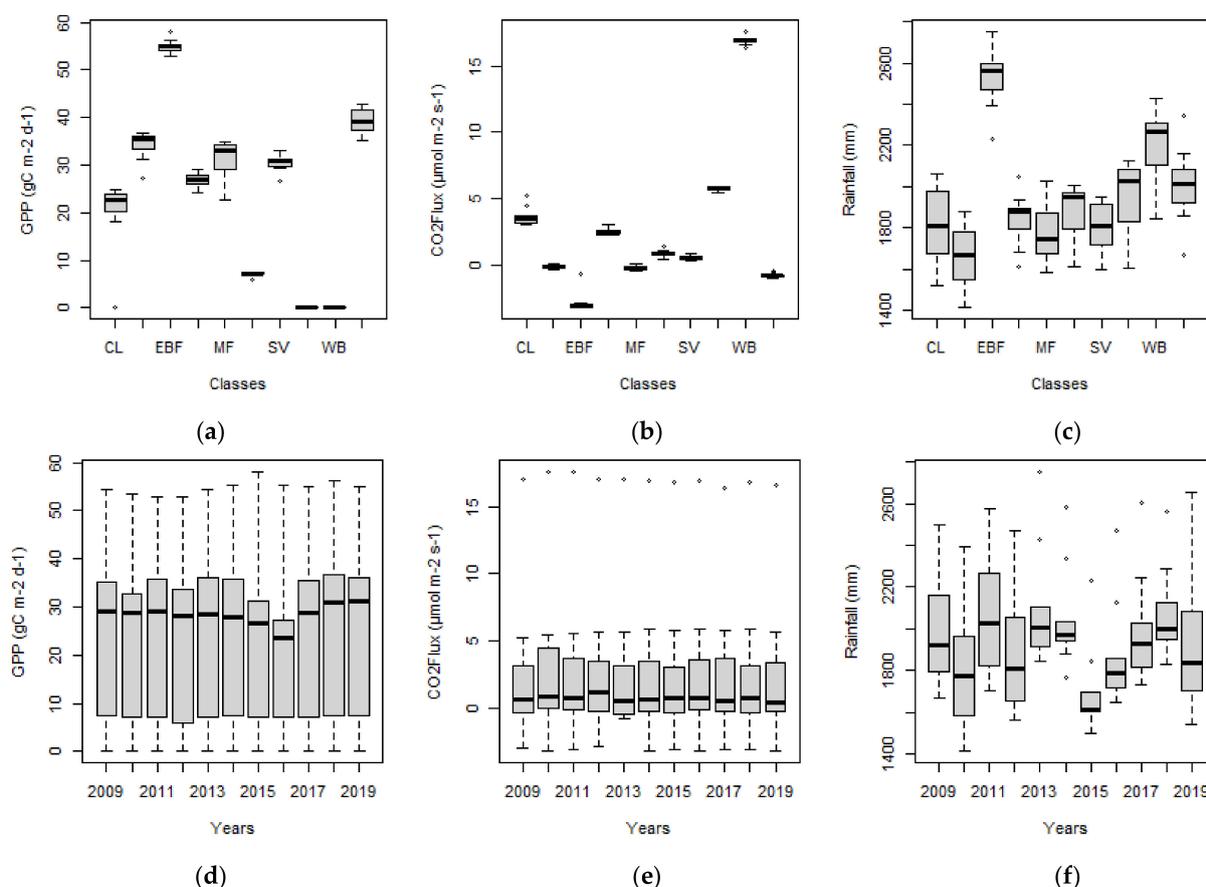


Figure 4. Boxplot of the median, 25% and 75% quartiles and outliers' data for classes (in alphabetical order CL, DBF, EBF, MF, GL, PW, SV, UBL, WB and WSB) of the (a) GPP, (b) CO₂Flux and (c) Rainfall variables and for years for (d) GPP, (e) CO₂Flux and (f) Rainfall variables. Croplands (CL); Deciduous Broadleaf Forests (DBF); Evergreen Broadleaf Forests (EBF); Grasslands (GL); Mixed Forests (MF); Permanent Wetlands (PW); Savannas (SV); Urban and Built-up Lands (UBL); Water Bodies (WB) and Woody Savannas (WSV).

Differences between land use classes were observed for GPP ($X^2 = 103.96$), CO₂Flux ($X^2 = 106.73$) and Rainfall ($X^2 = 65.12$) by the Kruskal-Wallis test ($p < 0.05$). The Dunn's post-hoc test showed that differences in GPP were between EBF and CL, GL, UBL, PW and WB. The DBF and WSV classes were different from UBL, PW and WB. MF and SV were different from UBL and WB. It is also interesting to observe that EBF did not differ from the DBF, MF, SV and WSV classes, all these considered as forest classes, which had medians of 52.90, 34.68, 31.53, 31.32 and 39.84 gC m⁻², respectively. Outliers below the minimum values were observed for SV, DBF, CL and PW, of 23.53, 22.90, 16.88 and 0.43 gC m⁻², in 2016, respectively (Figure 4a and Table S1).

The EBF showed the highest value of 52.90 gC m⁻² and an outlier above the maximum values was observed, of 55.43 gC m⁻², in 2018. The PW had the lowest GPP values, of 0.6 gC m⁻². The amounts of total carbon absorbed in an area is related to the area extension and these were, on average, 176.63, 25.54, 11.46, 8.80, 1.17, 0.47, and 0.07 Tg C year⁻¹ for EBF, SV, GL, WSV, CL, DBF, and MF classes, respectively. The UBL and WB classes did not absorbed any carbon as these do not represent vegetation areas, and the PW class absorbed only 0.03 Tg C year⁻¹ (Figure 4a and Table S1).

For the CO₂Flux variable, the Dunn test and the boxplot showed a difference between EBF and CL, GL, UBL, PW and WB, and a similarity between forest classes DBF, MF and WSV, except for SV, with values of -3.09, -0.06, -0.26, -0.65 and 0.28 μmol m⁻² s⁻¹, respectively. DBF and MF classes were different from CL, UBL and WB. The WSV class was

different from CL, GL, SV, UBL, PW and WB, while SV was also different from WB. PW was different from WB but similar to UBL. The DBF, MF and SV classes oscillated between negative and positive values, while PW was positive, but also close to zero. Certainly, these values made DBF and MF more similar, as also occurred for SV and PW, as CO₂Flux values increased from forest classes to more anthropic-use classes, following the order EBF, WSV, MF, DBF, SV, PW, GL, CL and UBL (Figure 4b and Table S1).

In the Rainfall, the Dunn test specified that there was a difference between EBF and DBF, CL, GL, MF, SV, and PW, but not for UBL and WB, which had values above 1605 mm. In addition, the DBF, MF and SV classes was different from WB, and DBF was also different from WSV, because DBF, MF, SV, GL, and CL were the classes with the lowest precipitation, with values below 1533 mm. WSV, PW and UBL had averages between 1902 and 1929 mm, while EBF and WB were 2473 and 2234 mm (Figure 4b and Table S1).

The Cluster analysis was carried out to improve the visualization of the groupings, which demonstrated that EBF was the most distant grouping amongst the land use and land cover types of the BLA, and that it was closest to DBF and WSV for those variables capable of measuring absorption and above ground carbon stock, finally being grouped according to the rainfall regime of these classes (Figure S6).

The GL and CL classes were similar because, despite representing median GPP values of 25.71 and 21.44 gC m⁻², CO₂Flux values were always positive at 2.83 and 3.50 μmol m⁻² s⁻¹, respectively. The UBL and WB groups represented the highest emissions through CO₂Flux, of 5.76 and 15.92 μmol m⁻² s⁻¹, respectively, and no biomass production (GPP = 0), and PW merged with this group, mainly due to not producing biomass efficiently, with only 0.6 gC m⁻² over the years (Figures 4a,b and S3).

The MF and SV classes were similar because they produced more biomass than the GL and CL groups, 31.53 and 31.32 gC m⁻², but oscillated between carbon absorption and emission, by CO₂Flux, between 0.11 and -0.53, and 0.69 and -0.08 μmol m⁻² s⁻¹, respectively, as well as what is observed for DBF, with GPP only a little higher, at 34.68 gC m⁻². WSV showed higher biomass production compared to previous classes, of 39.84 gC m⁻², but absorbed carbon every year (CO₂Flux < 0), as well as EBF; however, this latter class was that which obtained the highest carbon absorption by GPP and CO₂Flux, combined with the highest amount of Rainfall compared to the other classes (Figures 4a–c and S3).

In the Kruskal-Wallis and Dunn tests for comparison between years in the BLA, only the Rainfall variable showed a significant difference ($\chi^2 = 28.61$, $p < 0.05$). The Dunn test showed that this difference was between 2013 and 2015 and between 2015 and 2018, which had values of 2092, 1689 and 2026 mm, respectively. The Rainfall values decrease for the different classes following this order: EBF, WB, WSV, UBL, PW, GL, SV, CL, MF and DBF, with maximums of 2792 (2013), 2453 (2013), 2182 (2011), 2120 (2018), 2098 (2011), 2091 (2009), 1983 (2013), 2074 (2018), 2016 (2013) and 1941 (2013), and lows of 2163 (2015), 1895 (2015), 1706 (2015), 1605 (2015), 1702 (2010), 1533 (2015), 1530 (2015), 1527 (2010), 1528 (2010) and 1475 (2010) mm. Outliers between 2013 and 2015, above the maximum values and lower than the minimum values, were observed for the Rainfall variable, with EBF being the class responsible for the above outliers (Figures 4f and S3).

The GPP values were in descending order from the forest classes to the most anthropic classes as follows, EBF, WSV, DBF, MF, SV, GL, CL and PW, with maximums of 55.43 (2018), 43.10 (2018), 39.20 (2018), 36.23 (2017), 36.00 (2019), 31.25 (2019), 24.03 (2018) and 0.73 (2014), and minimums of 50.23 (2013), 35.53 (2016), 22.90 (2016), 22.35 (2016), 23.53 (2016), 16.25 (2016), 16.88 (2016) and 0.43 (2016) gC m⁻². The EBF, DBF, WSV and CL classes had the highest GPP in 2018, but in general the maximum values were observed after 2017, while the minimum values were in 2016. In the EBF class, a decrease in GPP was observed shortly after drought events, from 53.59 gC m⁻², in 2010, to 52.89 and 52.99 gC m⁻², in 2011 and 2012, and from 58.07 gC m⁻², in 2015, to 55.35 gC m⁻², in 2016 (Figures 4d and S3).

The EBF and WSV classes had lower CO₂Flux in 2014, of -3.55 and -0.98 μmol m⁻² s⁻¹, while DBF and MF were -0.28 (2018) and -0.53 (2009) μmol m⁻² s⁻¹, respectively. Outliers above the maximum values were seen for all years in the CO₂Flux variable for the

WB class. The DBF and MF classes had minimums in 2013 and maximums in 2012 and 2010, respectively (Figures 4e and S3).

The years 2014 and 2018/19 showed the highest GPP averages of 24.26, 26.24 and 26.03 gC m^{-2} , respectively, and the lowest CO_2Flux . In addition, the years with the lowest Rainfall values, such as 2010 and 2015/16, demonstrated the dependence of these indices on climatic factors, with lower GPP averages, of 22.76 (2015) and 19.24 (2016) gC m^{-2} , and higher CO_2Flux of 2.80 (2010) $\mu\text{mol m}^{-2} \text{s}^{-1}$ (Figure 4d–f and Figure S3).

The correlation between the CO_2Flux and GPP variables was strong and negative, at -0.75 , which also means that the increase in one influences the decrease in the other, and was statistically significant for the CL and PW classes, at -0.65 and -0.69 , respectively. Low correlation between the variables CO_2Flux and GPP with Rainfall was observed and this was due to the non-linearity between them, seen the scatterplot at the lower left part of the graph (Figure 5).

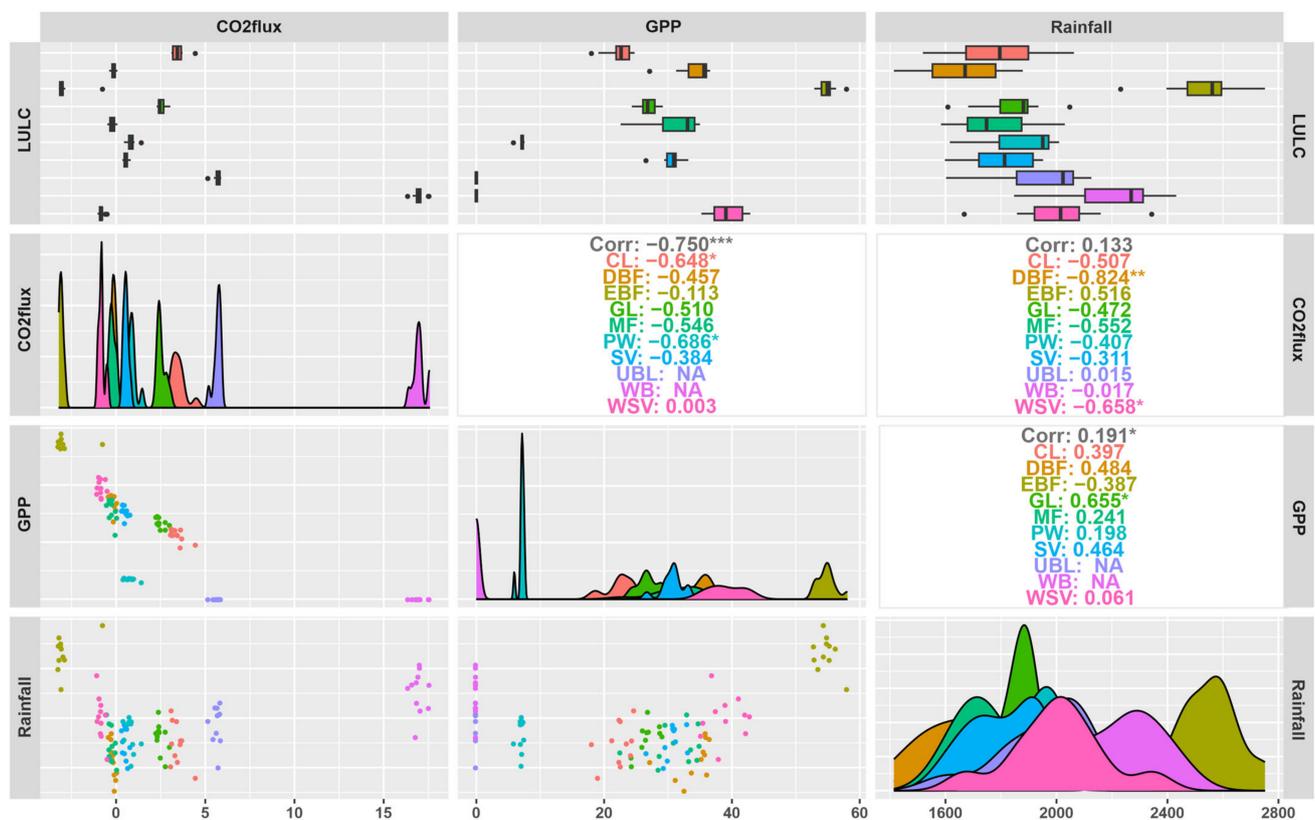


Figure 5. Scatterplot of the distribution and the correlations between the GPP, CO_2Flux and Rainfall variables in different types of land use and land cover. Values shown in gray indicate the overall correlation, while colored values indicate the correlation between land use and land cover. *, ** and ***: significant at 5, 1 and 0.1% probability by *t*-test, respectively. Land use and land cover (LULC); Croplands (CL); Deciduous Broadleaf Forests (DBF); Evergreen Broadleaf Forests (EBF); Grasslands (GL); Mixed Forests (MF); Permanent Wetlands (PW); Savannas (SV); Urban and Built-up Lands (UBL); Water Bodies (WB) and Woody Savannas (WSV).

In the correlation between CO_2Flux and Rainfall, the DBF and WSV classes had a strong negative correlation of -0.82 and -0.66 , which demonstrates that the increase in Rainfall values causes a decrease in CO_2Flux values. Only EBF and UBL showed a positive, though weak, correlation, which showed that the increase in Rainfall values can increase CO_2Flux values. In the correlation GPP with Rainfall variables, only EBF presented a negative correlation, also weak; a strong and positive correlation was observed for the GL class of 0.66 (Figure 5).

The first two principal components (Dim1 and Dim2), which analyzed the cluster in the classes and variables, accounted for 58.4% and 35.4% of the total variance between data. Greater affinity was observed for GPP with EBF and with WSB and was more distant for WB and UBL. The CO₂Flux variable was more associated with the WB class, also being close to the UBL due to the higher values for this variable. The other classes with the presence of vegetation ranged between negative and positive or were close to zero, which may be related to the poor ability of the CO₂Flux index to characterize these classes. In addition, Rainfall was closer to the EBF and WB classes, as they were those that had values above 2200 mm for all years of the studied period (Figure 6).

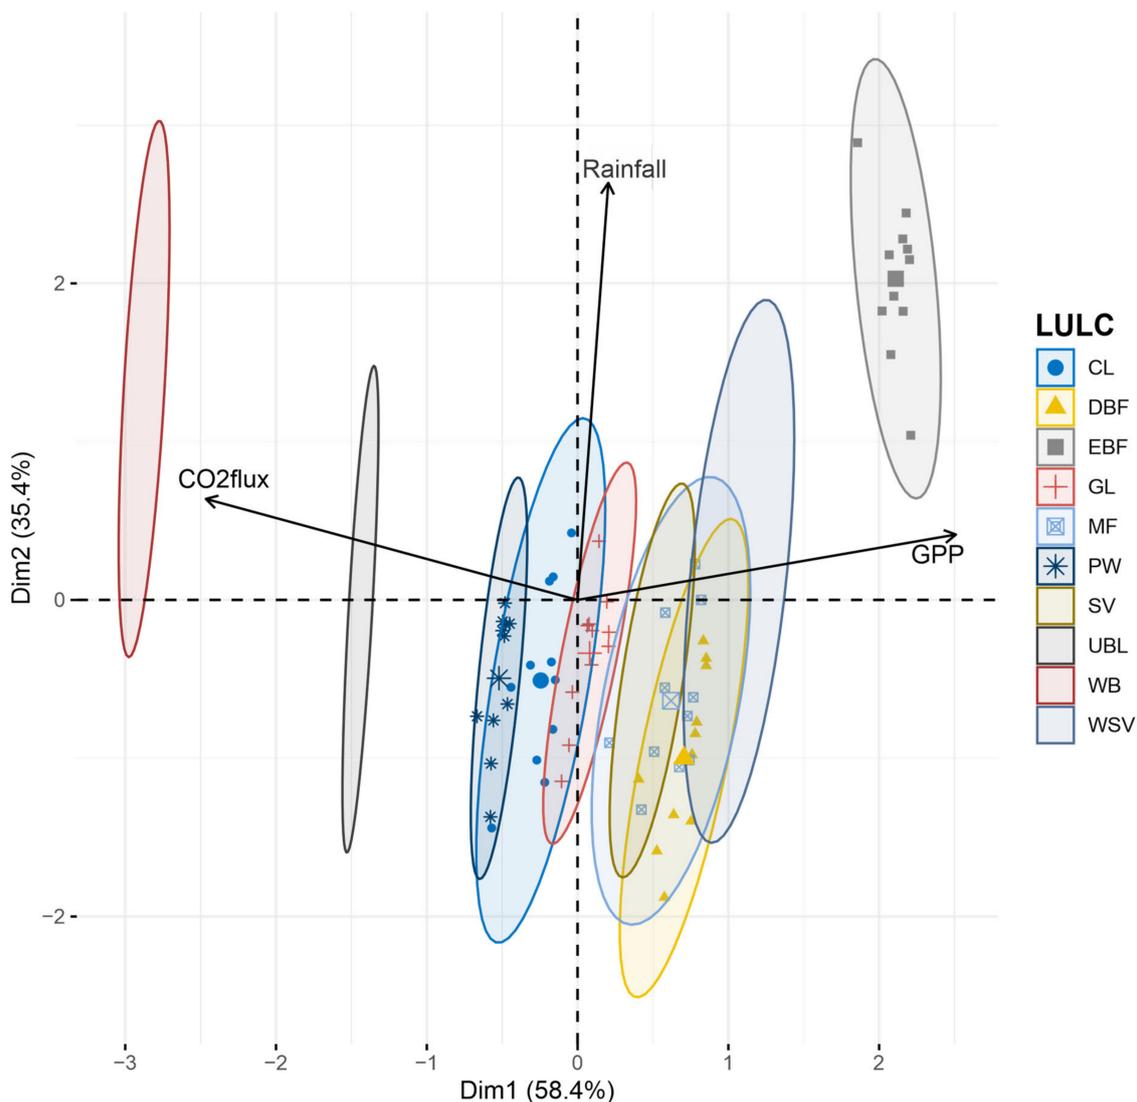


Figure 6. Principal component analysis for GPP, CO₂Flux and Rainfall variables in different land use and land cover between 2009 to 2019. Land use and land cover (LULC); Croplands (CL); Deciduous Broadleaf Forests (DBF); Evergreen Broadleaf Forests (EBF); Grasslands (GL); Mixed Forests (MF); Permanent Wetlands (PW); Savannas (SV); Urban and Built-up Lands (UBL); Water Bodies (WB) and Woody Savannas (WSV).

With the purpose of evaluating the existence of monotonic trends in historical series of the three variables (GPP, CO₂Flux and Rainfall) over 10 classes of land use and land cover of the BLA (EBF, DBF, MF, WSV, SV, GL, PW, CL, UBL and WB), the Mann-Kendall test was used, which is more robust in terms of deviations from normality and in non-stationarity of historical series data, compared to other parametric tests [54,56]. Trend analysis was

performed by observing the Z value. Identification of years with a trend over the time series (2009–2019) for each variable was performed using the Pettitt Test. Points were selected where the classes had not changed over the years but were influenced by changes in the uses of adjacent classes (Table 4).

Table 4. *p*-value for the Mann-Kendall and Pettitt tests for GPP, CO₂Flux and Rainfall variables in the BLA, grouped by land use and land cover.

Classes	GPP			CO ₂ Flux			Rainfall		
	Mann-Kendall	Z	Pettitt	Mann-Kendall	Z	Pettitt	Mann-Kendall	Z	Pettitt
EBF	0.07 *	1.80	0.04 **	0.24	−1.18	0.56	0.56	0.58	0.79
DBF	0.58	0.55	0.42	0.64	−0.46	1.00	0.60	0.52	0.41
MF	0.44	0.77	0.01 ***	0.54	−0.61	0.80	0.76	0.30	0.13
WSV	0.29	1.06	0.28	0.92	0.10	1.00	0.21	−1.27	0.73
SV	0.94	0.07	1.00	0.28	−1.07	0.86	0.66	−0.43	1.00
GL	0.63	0.48	0.83	0.59	−0.54	1.00	0.19	−1.30	0.19
CL	0.22	1.22	0.10	0.39	−0.86	0.52	0.41	0.83	0.31
PW	0.74	−0.33	1.00	0.97	−0.04	1.00	0.34	−0.95	1.00
UBL	-	-	-	0.12	1.55	0.47	0.76	0.30	0.78
WB	-	-	-	0.76	−0.30	1.00	0.58	−0.56	0.65

*, ** and ***: significant at 10, 5 and 1% probability by Mann-Kendall and Pettitt tests.

For the EBF class, Mann-Kendall demonstrated an increase in GPP ($p < 0.1$) and Pettitt showed that 2013 ($p < 0.05$) had an increase in its values over the years. For other vegetative classes, such as MF ($p < 0.01$), this increase was observed mainly after 2016/17. Despite the observation of changes in land use and land cover, in general, no significant trends were detected in the data for the GPP, CO₂Flux and Rainfall variables by the Mann-Kendall and Pettitt tests. However, according to the Z value, a positive tendency for GPP was observed, mainly for EBF, WSV and CL, and a negative trend for CO₂Flux, for EBF and SV, throughout the years studied. A negative trend was also observed, that is, a decrease in Rainfall values over the years, for WSV, SV, GL, PW, and WB (Table 4).

4. Discussion

4.1. The Effect of Changes in Land Use and Land Cover on Indigenous Lands, Protected Areas and Other Important Areas of Conservation

In general, the land use and land cover classifications using the MCD12Q1 product showed good accuracy for the BLA over the years studied. Studies report its high accuracy in classifying land use and land cover, mainly for relatively stable classes such as water and forests [41,54–57].

The reduction observed in the forest classes, EBF, WSV and SV, was from 67.28%, 4.38%, 16.24%, in 2009 to 65.96%, 4.38%, 15.51%, in 2019, respectively, while anthropized areas, such as GL and CL, increased from 8.53% and 0.92%, in 2009, to 10.05% and 1.22%, in 2019, respectively, possibly characterizing deforestation [85].

The EBF was observed in the center, west and north of the Legal Amazon. As it is the largest type of forest in the BLA, the EBF class represents an important carbon sink [4,41,86]. This class is also known as Dense Ombrophylous Forest or Tropical Pluvial Forest [87], is the main phyto-physiognomy of the Amazon biome, and occurs in tropical, or even equatorial, areas where high rainfall is regularly distributed throughout the year [49,51,52,87]. This type of forest is mainly preserved over Indigenous Lands (IL) and Protected Areas (PA) in the region [2,25–27,29].

The indigenous lands in the Brazilian Amazon cover 27% of the area with forests, are home to 173 ethnic groups and are fundamental for the physical and sociocultural reproduction of indigenous peoples, in addition to being important areas for the conservation of regional and global biodiversity [2,25]. In addition, IL and PA correspond to half of the total forest area of the BLA, playing important roles in forest and biodiversity conservation and climate mitigation [2,26,27].

In Brazil, deforestation rates, and consequent changes in land use and land cover in forest areas protected by IL and PA are up to ten times lower than in areas without environmental protection. This is because these areas have greater forest cover and lower deforestation pressure compared to areas without environmental protection, which tend to have high deforestation pressures [2].

Similar to the EBF class, the SV and WSV represent the main phyto-physiognomies of the Cerrado biome [49,87] and both have suffered a reduction of 68,186.11 km². The SV class was observed in the Cerrado and Pantanal biomes and in their transitions to the Amazon biome [2,44,50], close to ILs, PAs and highways from the north, in the Parque do Tumucumaque IL, in the State of Pará, around the BR-210 and 174 highways, and in the São Marcos and Raposa Serra do Sol IL, in the State of Roraima, and in the Serra do Araçá State Park PA, in the State of Amazonas. In the central part, the SV class was observed in the agricultural regions of Mato Grosso, around the BR-163 highway to Santarém—PA and the BR-230 highway, from the State of Maranhão to Lábrea—AM, while into the south around the BR-364 highway to Mâncio Lima—AC [4,29,31,50,88].

The WSV class was observed in the northeast, from the Amazon River to its mouth in the Pacific Ocean, in Oiapoque—AM and in the east, around BR-230 highway, in the State of Maranhão, the Tapajós River, in the State of Pará, and in the entire perimeter of the BR-364 highway, especially in the cities of Comodoro, Sapezal and Campo Novo do Parecis—MT, some of the main soy producing cities in the State [34], and nearby Nambikwara IL [31,50,88].

In the gradient from northeast to south of the BLA, large areas of classes GL and CL were observed, appearing close to each other, mainly in the region of the “arc of deforestation” [2,89], a transition between Cerrado and Amazon biomes [44], which extends from the northeast of the State of Pará to the east of the State of Acre, accounting for the largest expanding agricultural frontier in the world [2,30,31,85].

The GL occurred mainly in the Middle East, where the Jalapão State Park and the Serra Geral Ecological Station PA are located, in the State of Tocantins, and the Nascentes do Rio Parnaíba National Park PA, in the State of Maranhão [4,50]. A significant portion was observed northeast of the Marajó island and north of the State of Roraima, both regions on the northern flank of the BLA. Other areas were observed in the central region of the Legal Amazon, such as the Parque do Tumucumaque and Munduruku, Báú, Menkragnoti, Panará, Paresi and Parque do Xingu IL, in the States of Pará and Mato Grosso [50,88]. This class is often reported as the vegetative class of high anthropization [8,42] and presents a high risk of frequent fires [15,23,90].

As shown by the district of Santo Antônio do Matupi, the intensification of the land use and land cover changes processes occur in ILs and PAs, such as the Campos Amazônicos National Park, the Aripuanã National Forest, Campos de Manicoré Environmental PA and the Manicoré Biological Reserve, which were created with the aim of protecting the biological diversity and control the process of occupation of the region [82].

In addition, the district of Santo Antônio do Matupi is close to the Diahui, Pirahã, Sepoti, Tenterim Marmelos, and Tenterim do Igarapé Preto IL, which are also responsible for environmental, ecological, and social preservation [2,25]. However, this district is known to be an important timber extraction region and, therefore, a major destroyer of mature forests. This fact was confirmed when losses of primary forests in Santo Antônio do Matupi were observed, especially between 2004 and 2018, when 63.28% of the area was converted into pastures [83].

These intensification processes were induced by the political scenario in Brazil, as a result of significant changes in environmental laws, policies and regulations that favored deforestation and the expansion of agricultural activities in areas close to the forest [24,28,29,91–93]. Thus, in the BLA, the conversion of forests to pastures and agricultural lands had relatively high emissions, exceeding 340 Tg C year⁻¹ in 2010 [20], because the drought of this year was likely to have influenced these extremely high emissions [40]. In addition, those areas with the greatest fragmentation of forests and close to major

roads, pasture areas, agriculture and Cerrado regions are the areas with the highest risk of frequent fire [15,23,35,36,90,94]. Forest conservation in IL/PA has also faced increasing threats from weakened environmental laws and regulations, changes in government policies and massive economic development, such as changes in use and occupation in these areas [2,26,27].

Of the areas observed with significant change in land use and cover during the time series analyzed in the present work, most are close to the IL [26]. To the north of the State of Roraima, the IL of Ananás, Anaro, Aningal, Anta, Araçá, Barata Livramento, Bom Jesus, Boqueirão, Cajueiro, Canaúanim, Jabuti, Jacamim, Malacacheta, Mangueira, Manoa/Pium, Moskow, Muriru, Ouro, Pium, Ponta da Serra, Raimundão, Raposa Serra do Sol, Santa Inez, São Marcos, Serra da Moça, Sucuba, Tabalascada and Truaru are important regions for the Taulipáng, Makuxi, Ingarikó and Wapixana ethnic groups. To the north of the State of Pará, the Tumucumaque Park IL protects the Wayana and Apalaí ethnic groups. To the northeast are the Amanayé, Anambé, Timbira and Tembê ethnic groups; between the BR-230 and BR-364 highways, the Arara do Pará, Araweté, Asurini do Xingu, Kayapó, Kuruáya and Parakanã ethnic groups were cornered, and to the south, part of the Munduruku IL, which inhabits the Mundurukús, was affected [26,88].

Uaçá IL, north of the State of Amapá, where the Karipunas live, has also suffered the pressures caused by changes in land use and land cover. In the State of Maranhão, the Gavião Pukobiê, Guajá, Kanela, Krikati, Tenetehara and Timbira ethnic groups were affected. In the State of Tocantins, the Apinayé, Ava-Canoeiro, Javaé, Ka'apor, Karajá, Krahô, Tapirapé and Xerente ethnic groups were also affected [26,88].

In the State of Mato Grosso, all indigenous lands in the south were affected, e.g., the Bakairí, Boróro, Chiquitáno, Guató, Halotesu, Nambikwára, Paresí, Umutina, Wasusu and Xavante ethnic groups, with emphasis on the Boróros, Paresís and Xavantes, who suffered major reductions in their lands. To the east of the State of Mato Grosso, there is still a great threat to the Aweti, Ikpeng, Kaiabi, Kalapalo, Kamayurá, Karajá, Kayapó, Kisêdjê, Kuikuro, Matipú, Mehinaku, Nahukuá, Tapayuna, Tapirapé, Trumái, Wauja, Xavantes, Yawalapití and Yudjá ethnic groups, and in the northwest, the Apiaká, Cinta Larga, Enawenê-Nawê, Irántxe, Kaiabi, Mynky, Rikbaktsa, Suruí de Rondônia and Zoró ethnic groups are under threat from the new agricultural frontiers and deforestation [26,34,44,88].

4.2. Spatial Carbon Flux in the Legal Amazon

The greater values for GPP were found in the north, west and central areas, coinciding with the forest classes, mainly the EBF class, and the maximum values agree with those of Zhang et al. [10], who also observed a higher peak of GPP near the equator. [8,15].

On the other hand, the EBF, MF, SV and WSV decreased in extension. while GL, CL, UBL, PW and WB classes increased, these land use and land cover changes affecting the whole region due to the decrease in GPP, which may lead to an exacerbation of climate change [43], as seen during 2015/16. 2015/16 was a year of extreme drought due to El Niño [95], and these changes aggravate emissions, due to greater carbon losses from deforestation and forest fires. Moreover, those areas that are no longer forested also tend to absorb less carbon [35,36,94]. Thus, in this area there is a deficiency in carbon absorption, with poor or no absorption [15]. Similar to the findings in this work, carbon absorption averaged $75.1 \text{ gC m}^{-2} \text{ year}^{-1}$ in the northern and central parts of the BLA, and less than $40 \text{ gC m}^{-2} \text{ year}^{-1}$ in the eastern and southern parts of the region [8,15].

The lowest values of CO_2 Flux were found in the central and western regions of the BLA, represented by the forest classes EBF, DBF, MF and WSV, with the EBF class having the smaller value [34], and the highest values were also observed in the border between the northeast and south regions, where the SV, GL, CL, UBL, PW and WB classes were verified [34,42].

Therefore, it can be verified that forest areas that were converted to other uses resulted in higher CO_2 Flux values, which characterize CO_2 sources, while large areas of continuous

forest tend to have lower values and contribute positively to the balance of carbon as sinks, helping to mitigate the impacts of climate change [18,34,42].

The lowest precipitation was observed in the east to south edges of the studied area and in the State of Roraima, areas corresponding to the Cerrado biome [4,49], or the transition areas between Amazonia-Cerrado biomes [44], as observed for the previous variables, with the lowest GPP and highest CO₂Flux, where the SV, GL, CL and UBL classes were verified. This fact occurs due to the climate regime of the Cerrado biome, of the “Aw” type (tropical climate, with dry winter), on the border between east and south of the BLA, with well-defined rainy and dry periods [51,52].

The spatial distribution of XCO₂ hotspots was concentrated in the central and south-eastern region of the BLA, where the majority of the anthropic classes were observed, represented by higher CO₂ emissions compared to forests, and was influenced by climate change [16,17,21,96] and land use and cover changes [93].

Most of the central, north and west regions of the BLA showed insignificant spatial clusters or coldspots at the 90% confidence level, demonstrating a certain balance of XCO₂, regions coinciding with the EBF class (main forest class). In the eastern Amazon, spatial coldspots were found with 90% confidence, and more representative in 2016 [97]. Hotspots showed lower values in 2018 than in other years, showing a 0.7% reduction in annual averages of XCO₂, compared to 2015 [34].

As expected, the maximum values of precipitation were found in the regions of the State of Amapá and the northwest of Amazonas and northeast of Pará, close to the Equator, which has an “Af” type climate, characterized by high temperatures and a rainy season all year round [51,52]. These values explain the findings for GPP, in which greater precipitation also shows greater absorption and storage of carbon per area and vice versa. In places of high precipitation, higher GPP values were observed, while for dry places, lower values occurred [9].

The CHIRPS data were satisfactory for the spatiotemporal assessment of precipitation in the BLA and represented an efficient alternative to data from meteorological stations [43]. Spatially, it was possible to observe the damage caused in 2010 and 2015, in which there was a more pronounced reduction in rainfall, especially in 2015 [15], in which there was a significant decrease of rainfall in the “arc of deforestation” [2,30], increasing greenhouse gas emissions in the most anthropized classes [20]. This low precipitation was observed in the State of Mato Grosso, followed by the States of Rondônia and Acre, in the south and southwest regions in the Brazilian Amazon, with rainfall below 1360 mm and, in extreme cases, these values were below 520 mm [15]. This is likely to have occurred due to the highest number of fires observed in 2015 [20].

4.3. Carbon Analysis by Land Use and Land Cover

The non-grouping was sensitive to normality; however, the grouped normality test was more sensitive in presenting the classes or years responsible for the heterogeneous distribution in relation to the center [69]. The grouping proved to be more assertive for the analyzed data [68] and to be the most recommended for this type of evaluation [68,69,98]. It was also possible to understand, from the histogram, that there was irregularity in the data as it moved away from the center, suggesting that the data was not parametric [69], as seems to be common in these type of studies [72,77]. Considering these facts, the median was used, as this is the most recommended in order to compare groups in relation to mean values [70,71].

The highest GPP values occurred for forest classes EBF, DBF, MF, WSV and SV (>31.32 gC m⁻²), while the lowest occurred for anthropized classes GL, PW, CL, UBL and WB (<25.71 gC m⁻²). Similar to the findings in this work, carbon uptake ranged from 50 to 103 gC m⁻² year⁻¹, with an average of 75.1 gC m⁻² year⁻¹, for EBF classes, and less than 40 gC m⁻² year⁻¹, for more anthropized classes, such as CL, GL and forest fragments [15]. In the transition between semi-deciduous forest (DBF and MF) and Cerrado

(WSV and SV), GPP values of $27.7 \text{ gC m}^{-2} \text{ year}^{-1}$ (2003–2006) and $25.2 \text{ gC m}^{-2} \text{ year}^{-1}$, for GL were found [8].

The GL, CL and UBL classes were more positive and acted as the main sources of CO_2 emissions with land use and land cover changes [34], decreasing the amount of carbon absorbed by forests by reducing their area through deforestation [33].

The positive CO_2 Flux values ($>2.83 \mu\text{mol m}^{-2} \text{ s}^{-1}$) of anthropic classes (GL, CL and UBL) indicate carbon loss to the atmosphere and were the main sources of CO_2 emissions in the land use and land cover changes [34]. GL and CL showed values of 2.27 and $4.49 \mu\text{mol m}^{-2} \text{ s}^{-1}$, respectively, indicating carbon emission only higher than UBL and WB. The maximum CO_2 Flux values were observed for the regions classified as WB, representing the lowest carbon absorption, with the highest value for the year 2010, of $17.28 \mu\text{mol m}^{-2} \text{ s}^{-1}$. A study carried out in 2017 in the southern Amazonia forests (EBF) presented values close to -7.18 ± -2.92 and bare soils (BN), $6.46 \pm 2.23 \mu\text{mol m}^{-2} \text{ s}^{-1}$, with intermediate values for pasture (GL) [42].

As in GPP, the CO_2 Flux variable, used to measure the efficiency of the carbon absorption process related to vegetation demonstrated differences between the more vegetated classes when compared to the anthropic classes [34,61]. It can be observed that PW, UBL and WB were the largest sources of carbon, with almost no absorption over the years studied. GL and CL had the lowest carbon absorptions compared to the other vegetative classes and were still one of those that emitted the most carbon, and have been characterized as being the main class for changes in land use and land cover [34]. The DBF, MF, SV and WSV classes had higher carbon absorptions and lower carbon emissions which could be grouped as forest fragments, since these are randomly distributed in the studied area and are almost always associated with CL and GL.

The vegetated areas showed lower values ($<1 \mu\text{mol m}^{-2} \text{ s}^{-1}$), negative for the typical forest classes, EBF and WSV ($<-0.65 \mu\text{mol m}^{-2} \text{ s}^{-1}$), representing the highest carbon absorption and capture [18]. Furthermore, these values were lower the further away from water bodies, mainly for EBF. Studies have highlighted a substantial increase in carbon fixation for EBF areas because they comprise most of the Amazon rainforest (~65%), and for MF and WSV only slightly lower values in NPP (proportional to GPP) were observed [41].

Maximum precipitation values were observed for the years 2013, in EBF class, and 2011 or 2018, for more anthropized areas, years of negative anomalies, and the minimums were for the years 2010 and 2015, for all classes, i.e., years of positive anomalies [95]. Only for the EBF class, in 2013, did the GPP decrease due to reduced availability of shortwave radiation because of cloud cover [18,52,99], and for CO_2 Flux variable the EBF had the lowest value in 2010 and the highest in 2013. In general, the highest CO_2 Flux values were observed in 2010 and/or 2015, indicating carbon emissions [34].

In short, the lowest value of CO_2 Flux and the highest values of GPP and Rainfall variables were observed for the EBF class. DBF, MF, WSV, SV and PW classes were close to zero for CO_2 Flux, while GL, CL and UBL were between 2 and $6 \mu\text{mol m}^{-2} \text{ s}^{-1}$. For GPP, most classes were around 20 and 42 gC m^{-2} and the UBL and WB classes were null for GPP, because they do not represent vegetation. The highest Rainfall values coincided with areas classified as forests [100], while the lowest were in anthropized areas [93] and with Cerrado phyto-physiognomies [87]. Over forest areas, higher values of GPP and Rainfall were observed, above $40.5 \text{ gC m}^{-2} \text{ year}^{-1}$ and 2000 mm, and lower values of XCO_2 and CO_2 Flux, below 400 ppm and $-0.5 \mu\text{mol m}^{-2} \text{ s}^{-1}$, respectively.

EBF, the largest forest class in the BLA, absorbed an average of $176.63 \text{ Tg C year}^{-1}$; however, in the period evaluated, a loss of $66,452.69 \text{ km}^2$ was observed, failing to absorb and store 3.52 Tg C . In addition, the EBF, MF, WSV and SV forest classes together absorbed an average of $211.05 \text{ Tg C year}^{-1}$; however, they suffered losses of $135,922.34 \text{ km}^2$ in area between 2009 and 2019, which meant that 5.82 Tg C less was absorbed in the period studied, due to land use and land cover changes. The GL and CL classes, with the main land use conversions, absorbed about $12.63 \text{ Tg C year}^{-1}$. These classes increased by $85,355.24$ and $14,985.15 \text{ km}^2$, absorbing 2.19 and 0.32 Tg C , which corresponded to 1.32 and 3.19 Tg C

less than EBF class in these increased areas, respectively, and emitting $\pm 2\times$ more (2.83 and $3.50 \mu\text{mol m}^{-2} \text{s}^{-1}$) than EBF ($-3.09 \mu\text{mol m}^{-2} \text{s}^{-1}$) alone absorbed and stored (Table S1). Such results evidence that the BLA has undergone changes in land use and cover, and this represents an increase in GHG emissions, which contribute to global warming [15,29,101].

In the EBF class, a decrease in GPP was observed shortly after the dry periods, from 2010 to 2011 and 2012, and from 2015 to 2016. For the EBF, the correlation showed that the increase in the Rainfall values can increase CO_2Flux and decrease GPP values. De Oliveira et al. [24] report that, after three years of burning, there were disturbances in the carbon ratio and seasonality of forest regions compared to the previous three years; the burned forest then presented a higher GPP, due to regrowth. In this sense, for the driest years in the BLA, an increase in values can be found for GPP, as seen mainly for 2015/16 [15]. However, this work did not address the relationship between the fires that occurred over these years.

In addition, below average rainfall between 2012 and 2018, except in 2013, significantly limited vegetation growth, reducing the photosynthetic absorption of CO_2 from the atmosphere, and led to a reduction in GPP and an increase in CO_2Flux [41]. The authors also reported that the increase in rainfall, as in 2013 and 2017/18, improved these rates in later years [18], which occurred for the other vegetation classes. Recent studies show that climate change intensifies the dry season, generating stress in the ecosystem, especially in the eastern Amazon, the region with the highest rates of deforestation [41].

The correlation between the GPP and CO_2Flux variables and Rainfall was weak. Studies explain that precipitation has little influence on leaf production, at only 29.6%, and that the main climatic factor for this production is insolation (70.4%), as shown in this work [99]. It is reported that the temporal variability of CO_2Flux is positively correlated with precipitation [34], which was in agreement with our findings regarding the EBF class; however, the correlation was negative for most classes. Furthermore, an increase in NPP was observed in the Amazon Forest, in which the EBF will establish larger portions of carbon in future scenarios, while the MF, CS and WSV classes will present lower levels of NPP [41].

The sum of the first two principal components analyses explained 93.8% of the total data variation, considered adequate to respond to the relationships of the variables analyzed [73], allowing identification of the components that can help in the characterization of land use and land cover of the BLA derived from remotely sensed data [77]. A great affinity of GPP with EBF was observed, because this class had the highest biomass production by GPP values, as well as the largest forest classes in the BLA, and with the highest absorption and carbon sink by CO_2Flux [15]. However, the GPP was even more distant from WB and UBL, because these classes did not show any absorption in GPP [41]. It was possible to observe that GPP characterized classes with greater carbon absorption, as well as those that did not absorb any carbon, and the principal components analysis was efficient in demonstrating this.

It could be observed that the CO_2Flux variable was more associated with the WB and UBL classes, as these classes had the highest and most positive values, and this variable was the most distant for EBF, the class that had the lowest values in all years. This shows that the CO_2Flux variable was efficient in characterizing the carbon ratio for WB and UBL classes without vegetation, indicating higher CO_2 emission, more than that of the vegetative classes, and the carbon sink capacity of the EBF class [34,42].

Despite the changes in land use and land cover, with a decrease in forests and an increase in anthropized areas, in general, no significant trends were detected in the data for the GPP, CO_2Flux and Rainfall variables. Pettitt's test confirmed the stationarity of the historical series, i.e., the observations were invariant with respect to the chronology of their occurrences [80]. In this test, the p -value was less than 0.05 only for the EBF and MF classes, in which an increase in GPP values was observed after 2013 and 2017, respectively, years of La Niña influence [95]. In addition, Pettitt's test claimed to show a possible increase in GPP for forest classes over the years, i.e., increased CO_2 capture and carbon absorption [9,89,102].

Studies indicate that there will be expansion of carbon fixation in the western portion of the BLA ($>1500 \text{ gC m}^{-2}$). On the other hand, there will be an intensification of carbon emissions in the southern areas ($<710 \text{ gC m}^{-2}$) [41], in the sense demonstrated in this work.

The analysis of anomalies in the values of GPP and CO_2 Flux determined the impact of changes in CO_2 emissions and absorption that occurred in the region [15] and, therefore, it was important to estimate their temporal and spatial variations to understand the responses of the carbon to climate change and land use and land cover [12,16,17,21].

Although the evidence that the forest classes have increased their absorption and stock of carbon over the years, a change in precipitation was observed, with possible decreases in rainfall for the region of the “arc of deforestation” [2,30,31,44], where most of the changes in land use and land cover were observed, mainly from forest classes to other uses [34]. It should be noted that there was not enough evidence that changes in the land use and land cover of adjacent areas were responsible for modifying the carbon flux in the analyzed classes in the period studied, contrary to what has been reported [35,36].

However, a negative trend was observed, i.e., a decrease in Rainfall values over the years, for WSV, SV, GL, PW, and WB, which are located mainly in the region of greatest changes in land use and cover, from forest classes to other uses, characterized by deforestation [44]. Recent studies show that climate change intensifies the dry season, producing stress in the ecosystem, especially in the eastern Amazon, the region with the highest rates of deforestation, with strong presence of different types of croplands [41].

Aside from the fact that no trends from statistical analysis of increase in emissions induced by land use and land cover from remotely sensed data in the BLA were observed, carbon dioxide concentrations increased throughout the time series, with an increase between 2.2 and 2.8 ppm annually. Hotspots were also observed at the southern and eastern edges of the area, especially for more anthropized classes, and coldspots, in the center of the BLA, for forests [34]. The non-forest classes represented the largest carbon losses, given the lower capacity for processing carbon dioxide via photosynthesis in these ecosystems [42].

The comparison of CO_2 flux in changes in land use and land cover in the Brazilian Legal Amazon by the GPP and CO_2 Flux models is the main innovation of our work. It also gains prominence for associating the atmospheric CO_2 concentration through hotspots and precipitation over the years, which allowed the verification of trends in carbon fluxes for the Brazilian Legal Amazon during the 2009–2019 period.

5. Conclusions

Our study provides a source of information on land use, land cover relationships and carbon fluxes, in order especially to understand and promote more sustainable ecosystems in the BLA. The results suggest that there were changes in mature forests towards more anthropized ecosystems, such as pastures and croplands, from east to south of the BLA, mainly close to indigenous lands and conservation units, in the “arc of deforestation”.

Spatial and temporal variation in the carbon interactions between the biosphere and atmosphere were observed according to the climatic characteristics, land use and land cover. The CO_2 emissions increased between 2.2 and 2.8 ppm annually, with hotspots mainly observed for the southeastern region of the BLA, while CO_2 capture by GPP and CO_2 Flux showed an increase over the years, mainly after 2013, for forests in the north and west, and a decrease towards the southern parts of the region.

The forest absorbed 211.05 Tg C annually but lost 135,922.34 km^2 in area, which meant 5.82 Tg C less carbon absorbed due to its conversion to other land use and land cover types, while pasture and agriculture, the main conversions, increased by 100,340.39 km^2 and absorbed 1.32 and 3.19 Tg C less than EBF, emitting $\pm 2\times$ more than EBF alone, absorbed and stored.

To improve estimates and reduce uncertainties in the spatiotemporal distribution of carbon patterns in areas with strong land use and land cover changes, it is necessary to carry out more studies with field data. It is also strongly recommended to analyze a time

series over a longer period in order to check for possible anomalies or trends. However, studies like this are important for updating and implementing public policies, subsidizing a more strategic allocation of resources for forest restoration.

It is important to bring to light the climate dynamics and changes in the use and land cover occurring in one of the main responsible for carbon stocks in the world, the Amazon, which is essential for the fulfillment of the international agreements signed by Brazil to reduce CO₂ emissions and for the conservation of biodiversity and other ecosystem services.

Supplementary Materials: The following supporting information can be downloaded at: <https://www.mdpi.com/article/10.3390/rs15112780/s1>, Figure S1. Land use and land cover classes in the BLA between 2009–2019; Figure S2. Annual median of gross primary production (gC m⁻² year⁻¹) in the BLA between 2009 to 2019; Figure S3. Annual median of carbon dioxide fluxes (μmol m⁻² s⁻¹) in the BLA between 2009 to 2019; Figure S4. Accumulated precipitation (mm year⁻¹) retrieved from CHIRPS data of the Legal Amazon from 2009 to 2019; Figure S5. Histogram of the distribution frequency of GPP, CO₂Flux and Rainfall data; Table S1. Median values for the variables GPP, CO₂Flux and Rainfall, for each use and land cover in the Legal Amazon from 2009 to 2019; Figure S6. Cluster analysis for Evergreen Broadleaf Forests (EBF), Deciduous Broadleaf Forests (DBF), Mixed Forests (MF), Woody Savannas (WSV), Savannas (SV), Grasslands (GL), Permanent Wetlands (PW), Croplands (CL), Urban and Built-up Lands (UBL) and Water Bodies (WB) classes.

Author Contributions: Conceptualization, P.M.C.-C., M.L. and C.A.d.S.J.; methodology, C.A.d.S.J., P.E.T., P.M.C.-C., L.P.R.T. and N.L.S.J.; formal analysis, F.S.R., C.A.d.S.J., J.L.D.-S., R.D., G.d.O., J.F.d.O.J. and P.M.C.-C.; investigation, P.M.C.-C.; C.A.d.S.J., R.D., M.L. and G.d.O.; writing—original draft preparation, P.M.C.-C. and C.A.d.S.J.; writing—review and editing, C.A.d.S.J., N.L.S.J., P.E.T., J.F.d.O.J., L.P.R.T., R.D. and G.d.O. supervision, C.A.d.S.J. and P.M.C.-C. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Data Availability Statement: The datasets used and/or analyzed during the current study are available from the corresponding author upon reasonable request.

Acknowledgments: This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES)—Finance Code 001, National Council for Research and Development (CNPq). We would also like to thank the anonymous reviewers for providing insights to improve the manuscript. We are also thankful to the research laboratory of the State University of Mato Grosso (UNEMAT)—<https://pesquisa.unemat.br/gaaf/> (accessed on 15 March 2023). Thanks to Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso (FAPEMAT) for the financial support of the research project (0001464/2022 and 000125/2023), Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul (FUNDECT) to numbers 88/2021, and 07/2022, and SIAFEM numbers 30478 and 31333; and CNPq Research Productivity Scholars (processes 309250/2021-8; 303767/2020-0; 304979/2022-8).

Conflicts of Interest: The authors declare no conflict of interest. The funders had no role in the study design; in the collection, analyses, or interpretation of data; in the writing of the manuscript; or in the decision to publish the results.

References

1. Watson, J.E.M.; Evans, T.; Venter, O.; Williams, B.; Tulloch, A.; Stewart, C.; Thompson, I.; Ray, J.C.; Murray, K.; Salazar, A.; et al. The Exceptional Value of Intact Forest Ecosystems. *Nat. Ecol. Evol.* **2018**, *2*, 599–610. [[CrossRef](#)] [[PubMed](#)]
2. Qin, Y.; Xiao, X.; Liu, F.; de Sa e Silva, F.; Shimabukuro, Y.; Arai, E.; Fearnside, P.M. Forest Conservation in Indigenous Territories and Protected Areas in the Brazilian Amazon. *Nat. Sustain.* **2023**, *6*, 295–305. [[CrossRef](#)]
3. *BRASIL Base Legislação Da Presidência Da República—Lei Complementar No 124 de 03 de Janeiro de 2007*; Planalto: Brasília, Brazil, 3 January 2007.
4. IBGE Amazônia Legal. Available online: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=o-que-e> (accessed on 23 September 2021).
5. Qin, Y.; Xiao, X.; Wigner, J.P.; Ciais, P.; Brandt, M.; Fan, L.; Li, X.; Crowell, S.; Wu, X.; Doughty, R.; et al. Carbon Loss from Forest Degradation Exceeds That from Deforestation in the Brazilian Amazon. *Nat. Clim. Chang.* **2021**, *11*, 442–448. [[CrossRef](#)]
6. Aragão, L.E.O.C.; Poulter, B.; Barlow, J.B.; Anderson, L.O.; Malhi, Y.; Saatchi, S.; Phillips, O.L.; Gloor, E. Environmental Change and the Carbon Balance of Amazonian Forests. *Biol. Rev.* **2014**, *89*, 913–931. [[CrossRef](#)] [[PubMed](#)]

7. Garrett, R.D.; Cammelli, F.; Ferreira, J.; Levy, S.A.; Valentim, J.; Vieira, I. Forests and Sustainable Development in the Brazilian Amazon: History, Trends, and Future Prospects. *Annu. Rev. Environ. Resour.* **2021**, *46*, 625–652. [[CrossRef](#)]
8. De Almeida, C.T.; Delgado, R.C.; Galvão, L.S.; de Oliveira Cruz e Aragão, L.E.; Ramos, M.C. Improvements of the MODIS Gross Primary Productivity Model Based on a Comprehensive Uncertainty Assessment over the Brazilian Amazonia. *ISPRS J. Photogramm. Remote Sens.* **2018**, *145*, 268–283. [[CrossRef](#)]
9. Chagas, M.C.; Delgado, R.C.; de Souza, L.P.; de Carvalho, D.C.; Pereira, M.G.; Teodoro, P.E.; Silva Junior, C.A. Gross Primary Productivity in Areas of Different Land Cover in the Western Brazilian Amazon. *Remote Sens. Appl.* **2019**, *16*, 100259. [[CrossRef](#)]
10. Zhang, Y.; Xiao, X.; Wu, X.; Zhou, S.; Zhang, G.; Qin, Y.; Dong, J. A Global Moderate Resolution Dataset of Gross Primary Production of Vegetation for 2000–2016. *Sci. Data* **2017**, *4*, 170165. [[CrossRef](#)]
11. Pan, Y.; Birdsey, R.A.; Fang, J.; Houghton, R.; Kauppi, P.E.; Kurz, W.A.; Phillips, O.L.; Shvidenko, A.; Lewis, S.L.; Canadell, J.G.; et al. A Large and Persistent Carbon Sink in the World’s Forests. *Science* **2011**, *333*, 988–993. [[CrossRef](#)]
12. Wang, L.; Zhu, H.; Lin, A.; Zou, L.; Qin, W.; Du, Q. Evaluation of the Latest MODIS GPP Products across Multiple Biomes Using Global Eddy Covariance Flux Data. *Remote Sens.* **2017**, *9*, 418. [[CrossRef](#)]
13. Yan, H.; Wang, S.; Huete, A.; Shugart, H.H. Effects of Light Component and Water Stress on Photosynthesis of Amazon Rainforests during the 2015/2016 El Niño Drought. *J. Geophys. Res. Biogeosci.* **2019**, *124*, 1574–1590. [[CrossRef](#)]
14. Running, S.W.; Zhao, M. User’s Guide Daily GPP and Annual NPP (MOD17A2H/A3H) and Year-End Gap-Filled (MOD17A2HGF/A3HGF) Products NASA Earth Observing System MODIS Land Algorithm (For Collection 6). *Process. DAAC* **2019**, *490*, 1–37.
15. Da Silva Junior, C.A.; Lima, M.; Teodoro, P.E.; de Oliveira-Júnior, J.F.; Rossi, F.S.; Funatsu, B.M.; Butturi, W.; Lourençoni, T.; Kraeski, A.; Pelissari, T.D.; et al. Fires Drive Long-Term Environmental Degradation in the Amazon Basin. *Remote Sens.* **2022**, *14*, 338. [[CrossRef](#)]
16. Lin, X.; Chen, B.; Chen, J.; Zhang, H.; Sun, S.; Xu, G.; Guo, L.; Ge, M.; Qu, J.; Li, L.; et al. Seasonal Fluctuations of Photosynthetic Parameters for Light Use Efficiency Models and the Impacts on Gross Primary Production Estimation. *Agric. For. Meteorol.* **2017**, *236*, 22–35. [[CrossRef](#)]
17. Wagle, P.; Zhang, Y.; Jin, C.; Xiao, X. Comparison of Solar-induced Chlorophyll Fluorescence, Light-use Efficiency, and Process-based GPP Models in Maize. *Ecol. Appl.* **2016**, *26*, 1211–1222. [[CrossRef](#)]
18. Raju, A.; Sijkumar, S.; Kumar, P.; Burman, D.; Valsala, V.; Tiwari, Y.K.; Mukherjee, S.; Lohani, P.; Kumar, K. Very High-Resolution Net Ecosystem Exchange over India Using Vegetation Photosynthesis and Respiration Model (VPRM) Simulations. *Ecol. Modell.* **2023**, *481*, 110340. [[CrossRef](#)]
19. Berenguer, E.; Lennox, G.D.; Ferreira, J.; Malhi, Y.; Aragão, L.E.O.C.; Barreto, J.R.; Del Bon Espírito-Santo, F.; Figueiredo, A.E.S.; França, F.; Gardner, T.A.; et al. Tracking the Impacts of El Niño Drought and Fire in Human-Modified Amazonian Forests. *Proc. Natl. Acad. Sci. USA* **2021**, *118*, e2019377118. [[CrossRef](#)]
20. Ferreira Barbosa, M.L.; Delgado, R.C.; Forsad de Andrade, C.; Teodoro, P.E.; Silva Junior, C.A.; Wanderley, H.S.; Capristo-Silva, G.F. Recent Trends in the Fire Dynamics in Brazilian Legal Amazon: Interaction between the ENSO Phenomenon, Climate and Land Use. *Environ. Dev.* **2021**, *39*, 100648. [[CrossRef](#)]
21. Alves, L.M.; Marengo, J.A.; Fu, R.; Bombardi, R.J.; Alves, L.M.; Marengo, J.A.; Fu, R.; Bombardi, R.J. Sensitivity of Amazon Regional Climate to Deforestation. *Am. J. Clim. Chang.* **2017**, *6*, 75–98. [[CrossRef](#)]
22. Rammig, A.; Lapola, D.M. The Declining Tropical Carbon Sink. *Nat. Clim. Chang.* **2021**, *11*, 727–728. [[CrossRef](#)]
23. Amaral, S.S.; Costa, M.A.M.; Soares Neto, T.G.; Costa, M.P.; Dias, F.F.; Anselmo, E.; dos Santos, J.C.; de Carvalho, J.A. CO₂, CO, Hydrocarbon Gases and PM_{2.5} Emissions on Dry Season by Deforestation Fires in the Brazilian Amazonia. *Environ. Pollut.* **2019**, *249*, 311–320. [[CrossRef](#)] [[PubMed](#)]
24. De Oliveira, G.; Chen, J.M.; Matalveli, G.A.V.; Chaves, M.E.D.; Seixas, H.T.; Cardozo, F.d.S.; Shimabukuro, Y.E.; He, L.; Stark, S.C.; dos Santos, C.A.C. Rapid Recent Deforestation Incursion in a Vulnerable Indigenous Land in the Brazilian Amazon and Fire-Driven Emissions of Fine Particulate Aerosol Pollutants. *Forests* **2020**, *11*, 829. [[CrossRef](#)]
25. Crisostomo, A.C.; Alencar, A.; Mesquita, I.; Silva, I.C.; Dourado, M.F.; Moutinho, P.; Constantino, P.d.A.L.; Piontekowski, V. *Terras Indígenas Na Amazônia Brasileira: Reservas de Carbono e Barreiras Ao Desmatamento*; IPAM: Brasília, Brazil, 2015.
26. Begotti, R.A.; Peres, C.A. Brazil’s Indigenous Lands under Threat. *Science* **2019**, *363*, 592. [[CrossRef](#)]
27. Silveira, F.A.O.; Ferreira, M.C.; Perillo, L.N.; Carmo, F.F.; Neves, F.S. Brazil’s Protected Areas under Threat. *Science* **2018**, *361*, 459. [[CrossRef](#)] [[PubMed](#)]
28. Lima, M.; do Vale, J.C.E.; Costa, G.d.M.; dos Santos, R.C.; Correia Filho, W.L.F.; Gois, G.; de Oliveira-Junior, J.F.; Teodoro, P.E.; Rossi, F.S.; da Silva Junior, C.A. The Forests in the Indigenous Lands in Brazil in Peril. *Land Use Policy* **2020**, *90*, 104258. [[CrossRef](#)]
29. Lima, M.; Santana, D.C.; Junior, I.C.M.; da Costa, P.M.C.; de Oliveira, P.P.G.; de Azevedo, R.P.; Silva, R.d.S.; Marinho, U.d.F.; da Silva, V.; de Souza, J.A.A.; et al. The “New Transamazonian Highway”: BR-319 and Its Current Environmental Degradation. *Sustainability* **2022**, *14*, 823. [[CrossRef](#)]
30. Peres, C. Arco Do Desmatamento, Brasil | Prêmio Whitley. Available online: <https://whitleyaward.org/winners/informed-landscape-management-brazil/> (accessed on 13 March 2023).
31. WWF Estradas | WWF Brasil. Available online: https://www.wwf.org.br/natureza_brasileira/areas_prioritarias/amazonia1/ameacas_riscos_amazonia/infraestrutura_na_amazonia/estradas_na_amazonia/ (accessed on 13 March 2023).

32. Barlow, J.; Berenguer, E.; Carmenta, R.; França, F. Clarifying Amazonia's Burning Crisis. *Glob. Chang. Biol.* **2020**, *26*, 319–321. [[CrossRef](#)]
33. Silva Junior, C.H.L.; Carvalho, N.S.; Pessôa, A.C.M.; Reis, J.B.C.; Pontes-Lopes, A.; Doblaz, J.; Heinrich, V.; Campanharo, W.; Alencar, A.; Silva, C.; et al. Amazonian Forest Degradation Must Be Incorporated into the COP26 Agenda. *Nat. Geosci.* **2021**, *14*, 634–635. [[CrossRef](#)]
34. Rossi, F.S.; de Araújo Santos, G.A.; de Souza Maria, L.; Lourençoni, T.; Pelissari, T.D.; Della-Silva, J.L.; Oliveira Júnior, J.W.; e Silva, A.D.; Lima, M.; Teodoro, P.E.; et al. Carbon Dioxide Spatial Variability and Dynamics for Contrasting Land Uses in Central Brazil Agricultural Frontier from Remote Sensing Data. *J. S. Am. Earth Sci.* **2022**, *116*, 103809. [[CrossRef](#)]
35. Lovejoy, T.E.; Nobre, C. Amazon Tipping Point. *Sci. Adv.* **2018**, *4*, eaat2340. [[CrossRef](#)]
36. Lovejoy, T.E.; Nobre, C. Amazon Tipping Point: Last Chance for Action. *Sci. Adv.* **2019**, *5*, eaba2949. [[CrossRef](#)] [[PubMed](#)]
37. Roy, B. A Machine Learning Approach to Monitoring and Forecasting Spatio-Temporal Dynamics of Land Cover in Cox's Bazar District, Bangladesh from 2001 to 2019. *Environ. Chall.* **2021**, *5*, 100237. [[CrossRef](#)]
38. Alshari, E.A.; Gawali, B.W. Development of Classification System for LULC Using Remote Sensing and GIS. *Glob. Transit. Proc.* **2021**, *2*, 8–17. [[CrossRef](#)]
39. Ghosh, A.; Sharma, R.; Joshi, P.K. Random Forest Classification of Urban Landscape Using Landsat Archive and Ancillary Data: Combining Seasonal Maps with Decision Level Fusion. *Appl. Geogr.* **2014**, *48*, 31–41. [[CrossRef](#)]
40. Aragão, L.E.O.C.; Anderson, L.O.; Fonseca, M.G.; Rosan, T.M.; Vedovato, L.B.; Wagner, F.H.; Silva, C.V.J.; Silva Junior, C.H.L.; Arai, E.; Aguiar, A.P.; et al. 21st Century Drought-Related Fires Counteract the Decline of Amazon Deforestation Carbon Emissions. *Nat. Commun.* **2018**, *9*, 536. [[CrossRef](#)] [[PubMed](#)]
41. Da Silva, L.A.P.; de Souza, C.M.P.; da Silva, C.R.; Bolfe, É.L.; Rocha, A.M. Projection of Climate Change Impacts on Net Primary Productivity of the Legal Amazon—Brazil. *Cad. Geogr.* **2023**, *33*, 110–130.
42. Della-Silva, J.L.; Junior, C.A.d.S.; Lima, M.; Teodoro, P.E.; Nanni, M.R.; Shiratsuchi, L.S.; Teodoro, L.P.R.; Capristo-Silva, G.F.; Baio, F.H.R.; de Oliveira, G.; et al. CO₂ Flux Model Assessment and Comparison between an Airborne Hyperspectral Sensor and Orbital Multispectral Imagery in Southern Amazonia. *Sustainability* **2022**, *14*, 5458. [[CrossRef](#)]
43. De Oliveira-Júnior, J.F.; da Silva Junior, C.A.; Teodoro, P.E.; Rossi, F.S.; Blanco, C.J.C.; Lima, M.; de Gois, G.; Correia Filho, W.L.F.; de Barros Santiago, D.; dos Santos Vanderley, M.H.G. Confronting CHIRPS Dataset and in Situ Stations in the Detection of Wet and Drought Conditions in the Brazilian Midwest. *Int. J. Climatol.* **2021**, *41*, 4478–4493. [[CrossRef](#)]
44. Da Silva Junior, C.A.; Costa, G.d.M.; Rossi, F.S.; do Vale, J.C.E.; de Lima, R.B.; Lima, M.; de Oliveira-Junior, J.F.; Teodoro, P.E.; Santos, R.C. Remote Sensing for Updating the Boundaries between the Brazilian Cerrado-Amazonia Biomes. *Environ. Sci. Policy* **2019**, *101*, 383–392. [[CrossRef](#)]
45. Mataveli, G.; de Oliveira, G. Protect the Amazon's Indigenous Lands. *Science* **2022**, *375*, 275–276. [[CrossRef](#)]
46. Stark, S.C.; Breshears, D.D.; Arag, S.O.; Camilo Villegas, J.; Law, D.J.; Smith, M.N.; Minor, D.M.; Leandro Assis, R.D.E.; Roberti Alves Almeida, D.D.E.; Oliveira, G.D.E.; et al. Reframing Tropical Savannization: Linking Changes in Canopy Structure to Energy Balance Alterations That Impact Climate. *Ecosphere* **2020**, *11*, e03231. [[CrossRef](#)]
47. Smith, M.N.; Stark, S.C.; Taylor, T.C.; Schiatti, J.; de Almeida, D.R.A.; Aragón, S.; Torralvo, K.; Lima, A.P.; de Oliveira, G.; de Assis, R.L.; et al. Diverse Anthropogenic Disturbances Shift Amazon Forests along a Structural Spectrum. *Front. Ecol. Environ.* **2023**, *21*, 24–32. [[CrossRef](#)]
48. Flach, R.; Abrahão, G.; Bryant, B.; Scarabello, M.; Soterroni, A.C.; Ramos, F.M.; Valin, H.; Obersteiner, M.; Cohn, A.S. Conserving the Cerrado and Amazon Biomes of Brazil Protects the Soy Economy from Damaging Warming. *World Dev.* **2021**, *146*, 105582. [[CrossRef](#)]
49. Coutinho, L. *Biomas Brasileiros*; Oficina de Textos: São Paulo, Brazil, 2016.
50. IBGE Conheça Cidades e Estados Do Brasil. Available online: <https://cidades.ibge.gov.br/> (accessed on 21 November 2020).
51. Alvares, C.A.; Stape, J.L.; Sentelhas, P.C.; De Moraes Gonçalves, J.L.; Sparovek, G. Köppen's Climate Classification Map for Brazil. *Meteorol. Z.* **2013**, *22*, 711–728. [[CrossRef](#)] [[PubMed](#)]
52. Dubreuil, V.; Fante, K.P.; Planchon, O.; Neto, J.L.S. Os Tipos de Climas Anuais No Brasil: Uma Aplicação Da Classificação de Köppen de 1961 a 2015. *Rev. Fr.* **2018**, *37*, 1–26. [[CrossRef](#)]
53. Friedl, M.; Sulla-Menashe, D. MCD12Q1 MODIS/Terra+Aqua Land Cover Tipo Anual L3 Global 500 m SIN Grid V006. Available online: <https://lpdaac.usgs.gov/products/mcd12q1v006/> (accessed on 21 June 2022).
54. Ahmad, S.; Israr, M.; Ahmed, R.; Ashraf, A.; Amin, M.; Ahmad, N. Land Use and Cover Changes in the Northern Mountains of Pakistan; A Spatio-Temporal Change Using MODIS (MCD12Q1) Time Series. *Sarhad J. Agric.* **2022**, *38*, 1419–1429. [[CrossRef](#)]
55. Brown, C.F.; Brumby, S.P.; Guzder-Williams, B.; Birch, T.; Hyde, S.B.; Mazzariello, J.; Czerwinski, W.; Pasquarella, V.J.; Haertel, R.; Ilyushchenko, S.; et al. Dynamic World, Near Real-Time Global 10 m Land Use Land Cover Mapping. *Sci. Data* **2022**, *9*, 251. [[CrossRef](#)]
56. Caúla, R.H.; de Oliveira-Júnior, J.F.; de Gois, G.; Delgado, R.C.; Pimentel, L.C.G.; Teodoro, P.E. Nonparametric Statistics Applied to Fire Foci Obtained by Meteorological Satellites and Their Relationship to the MCD12Q1 Product in the State of Rio de Janeiro, Southeast Brazil. *Land Degrad. Dev.* **2017**, *28*, 1056–1067. [[CrossRef](#)]
57. He, S.; Li, J.; Wang, J.; Liu, F. Evaluation and Analysis of Upscaling of Different Land Use/Land Cover Products (FORM-GLC30, GLC_FCS30, CCI_LC, MCD12Q1 and CNLUCC): A Case Study in China. *Geocarto Int.* **2022**, *37*, 17340–17360. [[CrossRef](#)]

58. Gorelick, N.; Hancher, M.; Dixon, M.; Ilyushchenko, S.; Thau, D.; Moore, R. Google Earth Engine: Planetary-Scale Geospatial Analysis for Everyone. *Remote Sens. Environ.* **2017**, *202*, 18–27. [CrossRef]
59. Monteith, J.L. Solar Radiation and Productivity in Tropical Ecosystems. *J. Appl. Ecol.* **1972**, *9*, 747. [CrossRef]
60. Felton, A.J.; Goldsmith, G.R. Timing and Magnitude of Drought Impacts on Carbon Uptake across a Grassland Biome. *Glob. Chang. Biol.* **2023**, *29*, 2790–2803. [CrossRef] [PubMed]
61. Boas dos Santos, C.V. Modelagem Espectral Para Determinação de Fluxo de CO₂ Em Áreas de Caatinga Preservada e Em Regeneração. Master's Thesis, Universidade Estadual de Feira de Santana, Feira de Santana, Brazil, 2017.
62. Vermote, E. MOD09A1.006 Terra Surface Reflectance 8-Day Global 500 m. Available online: <https://lpdaac.usgs.gov/products/mod09a1v006/> (accessed on 10 July 2022).
63. Mustafa, F.; Wang, H.; Bu, L.; Wang, Q.; Shahzaman, M.; Bilal, M.; Zhou, M.; Iqbal, R.; Aslam, R.W.; Ali, M.d.A.; et al. Validation of GOSAT and OCO-2 against In Situ Aircraft Measurements and Comparison with CarbonTracker and GEOS-Chem over Qinhuangdao, China. *Remote Sens.* **2021**, *13*, 899. [CrossRef]
64. ESA GOSAT Objectives. Available online: <https://earth.esa.int/eogateway/missions/gosat/description> (accessed on 5 February 2022).
65. Getis, A.; Ord, J.K. The Analysis of Spatial Association by Use of Distance Statistics. In *Geographical Analysis*; Wiley Online Library: Hoboken, NJ, USA, 1992; pp. 189–206.
66. ESRI. *ArcGIS Desktop*; ESRI: Redlands, CA, USA, 2019.
67. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2018.
68. Hervé, M. *Aide-Mémoire de Statistique Appliquée à La Biologie—Construire Son Étude et Analyser Les Résultats à l'aide Du Logiciel R*; Université de Rennes: Rennes, France, 2016; 203p.
69. MacFarland, T.W.; Yates, J.M. *Using R for Biostatistics*; Springer International Publishing: Cham, Switzerland, 2021; ISBN 978-3-030-62403-3.
70. Dirikolu, L.; Waller, P.; Malveaux, K.; Lucas, C.H.; Lomnicka, I.; Pourciau, A.; Bennadji, H.; Liu, C.-C. Total Carbon Dioxide (TCO₂) Concentrations in Thoroughbred and Quarter Racehorses in Louisiana. *J. Equine Vet. Sci.* **2023**, *121*, 104220. [CrossRef] [PubMed]
71. Kroeger, M.E.; Wang, R.Z.; Suazo, D.; Dunbar, J. Simulated Nitrogen Deposition and Precipitation Events Alter Microbial Carbon Cycling during Early Stages of Litter Decomposition. 2022. preprint. Available online: <https://www.researchsquare.com/article/rs-2086262/v1> (accessed on 15 March 2023).
72. Díaz Arango, A. *Captura de Carbono En Un Sistema Agroforestal Con Cacao (Theobroma Cacao) En Victoria, Caldas*; Universidad de Caldas: Manizales, Colombia, 2023.
73. Regazzi, A.J.; Cruz, C.D. *Análise Multivariada Aplicada*; Editora UFV: Viçosa, Brazil, 2020; 401p.
74. Ward, J.H. Hierarchical Grouping to Optimize an Objective Function. *J. Am. Stat. Assoc.* **1963**, *58*, 236–244. [CrossRef]
75. Everitt, B.S.; Dunn, G. *Applied Multivariate Data Analysis*; Springer: New York, NY, USA, 1991.
76. Teodoro, P.; Cezar, C.; Corrêa, G.; Torres, F.E.; Silva, C.; Gois, G.; Delgado, R.C. Analysis of the Occurrence of Wet and Drought Periods Using Standardized Precipitation Index in Mato Grosso Do Sul State, Brazil. *J. Agron.* **2015**, *14*, 80–86.
77. Camarretta, N.; Ehbrecht, M.; Seidel, D.; Wenzel, A.; Zuhdi, M.; Merk, M.S.; Schlund, M.; Erasmí, S.; Knohl, A. Using Airborne Laser Scanning to Characterize Land-Use Systems in a Tropical Landscape Based on Vegetation Structural Metrics. *Remote Sens.* **2021**, *13*, 4794. [CrossRef]
78. Mann, H.B. Nonparametric Tests against Trend. *Econometrica* **1945**, *13*, 245–259. [CrossRef]
79. Kendall, M. *Rank Correlation Methods*; Charles Griffin: London, UK, 1975.
80. Pettitt, A.N. A Non-Parametric Approach to the Change-Point Problem. *Appl. Stat.* **1979**, *28*, 126. [CrossRef]
81. Richey, J.E.; Melack, J.M.; Aufdenkampe, A.K.; Ballester, V.M.; Hess, L.L. Outgassing from Amazonian Rivers and Wetlands as a Large Tropical Source of Atmospheric CO₂. *Nature* **2002**, *416*, 617–620. [CrossRef]
82. BRASIL Decreto s/n, de 11 de Maio de 2016. Área de Proteção Ambiental Dos Campos de Manicoré. Available online: <https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/amazonia/lista-de-ucs/apa-dos-campos-de-manicore> (accessed on 11 March 2023).
83. Duarte, M.L.; de Sousa, J.A.P.; de Castro, A.L.; Lourenço, R.W. Dynamics of Land Use in a Rural Settlement in the Brazilian Legal Amazon. *Rev. Bras. Ciências Ambient.* **2021**, *56*, 375–384. [CrossRef]
84. Wenzel, F. Depois Da Madeira Vem o Gado: O Desmatamento Em Santo Antônio Do Matupi. Available online: <https://idesam.org/conteudo/imprensa/depois-da-madeira-vem-o-gado-o-desmatamento-em-santo-antonio-do-matupi/> (accessed on 13 March 2023).
85. da Silva Junior, C.A.; Nanni, M.R.; de Oliveira-Júnior, J.F.; Cezar, E.; Teodoro, P.E.; Delgado, R.C.; Shiratsuchi, L.S.; Shakir, M.; Chicati, M.L. Object-Based Image Analysis Supported by Data Mining to Discriminate Large Areas of Soybean. *Int. J. Digit. Earth* **2019**, *12*, 270–292. [CrossRef]
86. Hui, D.; Deng, Q.; Tian, H.; Luo, Y. Climate Change and Carbon Sequestration in Forest Ecosystems. In *Handbook of Climate Change Mitigation and Adaptation*; Springer: New York, NY, USA, 2015; pp. 1–40.
87. Ribeiro, J.F.; Walter, B.M.T. As Principais Fitofisionomias Do Bioma Cerrado. In *Cerrado: Ecologia e Flora*; Sano, S.M., Almeida, S.P., Ribeiro, J.F., Eds.; Embrapa-Cerrados: Brasília, Brazil, 2008; p. 876.

88. Funai, F.N.d.Í. Terras Indígenas. Available online: <https://metadados.snirh.gov.br/geonetwork/srv/api/records/3fa8cc38-79b4-4aa1-8179-bba315baea4b> (accessed on 28 June 2022).
89. Silva, C.H.L.; Aragão, L.E.O.C.; Fonseca, M.G.; Almeida, C.T.; Vedovato, L.B.; Anderson, L.O. Deforestation-Induced Fragmentation Increases Forest Fire Occurrence in Central Brazilian Amazonia. *Forests* **2018**, *9*, 305. [[CrossRef](#)]
90. Zhang, Z.; Feng, Z.; Zhang, H.; Zhao, J.; Yu, S.; Du, W. Spatial Distribution of Grassland Fires at the Regional Scale Based on the MODIS Active Fire Products. *Int. J. Wildland Fire* **2017**, *26*, 209. [[CrossRef](#)]
91. Amigo, I. When Will the Amazon Hit a Tipping Point? *Nature* **2020**, *578*, 505–507. [[CrossRef](#)] [[PubMed](#)]
92. Cardil, A.; de-Miguel, S.; Silva, C.A.; Reich, P.B.; Calkin, D.; Brancalion, P.H.S.; Vibrans, A.C.; Gamarra, J.G.P.; Zhou, M.; Pijanowski, B.C.; et al. Recent Deforestation Drove the Spike in Amazonian Fires. *Environ. Res. Lett.* **2020**, *15*, 121003. [[CrossRef](#)]
93. Schielein, J.; Börner, J. Recent Transformations of Land-Use and Land-Cover Dynamics across Different Deforestation Frontiers in the Brazilian Amazon. *Land Use Policy* **2018**, *76*, 81–94. [[CrossRef](#)]
94. Da Silva Júnior, L.A.S.; Delgado, R.C.; Pereira, M.G.; Teodoro, P.E.; da Silva Junior, C.A. Fire Dynamics in Extreme Climatic Events in Western Amazon. *Environ. Dev.* **2019**, *32*, 100450. [[CrossRef](#)]
95. Noaa National Oceanic and Atmospheric Administration. NOAA’s Climate Prediction Center. Available online: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php (accessed on 13 March 2023).
96. Staal, A.; Flores, B.M.; Aguiar, A.P.D.; Bosmans, J.H.C.; Fetzer, I.; Tuinenburg, O.A. Feedback between Drought and Deforestation in the Amazon. *Environ. Res. Lett.* **2020**, *15*, 044024. [[CrossRef](#)]
97. Santos, G.A.d.A.; Morais Filho, L.F.F.; de Meneses, K.C.; da Silva Junior, C.A.; Rolim, G.d.S.; La Scala, N. Hot Spots and Anomalies of CO₂ over Eastern Amazonia, Brazil: A Time Series from 2015 to 2018. *Environ. Res.* **2022**, *215*, 114379. [[CrossRef](#)]
98. Chen, Y.; Wang, X.; Xie, Z. Land Cover Diversity: Reshaping the Socioeconomic Value of Land. *J. Environ. Manag.* **2023**, *332*, 117404. [[CrossRef](#)] [[PubMed](#)]
99. Wagner, F.H.; Hérault, B.; Rossi, V.; Hilker, T.; Maeda, E.E.; Sanchez, A.; Lyapustin, A.I.; Galvão, L.S.; Wang, Y.; Aragão, L.E.O.C. Climate Drivers of the Amazon Forest Greening. *PLoS ONE* **2017**, *12*, e0180932. [[CrossRef](#)] [[PubMed](#)]
100. Zhang, H.; Hagan, D.F.T.; Dalagnol, R.; Liu, Y. Forest Canopy Changes in the Southern Amazon during the 2019 Fire Season Based on Passive Microwave and Optical Satellite Observations. *Remote Sens.* **2021**, *13*, 2238. [[CrossRef](#)]
101. Faria, T.d.O.; Rodrigues, T.R.; Curado, L.F.A.; Gaio, D.C.; Nogueira, J.d.S. Surface Albedo in Different Land-Use and Cover Types in Amazon Forest Region. *Rev. Ambiente Agua* **2018**, *13*, 1–13. [[CrossRef](#)]
102. Zhang, C.; Brodylo, D.; Sirianni, M.J.; Li, T.; Comas, X.; Douglas, T.A.; Starr, G. Mapping CO₂ Fluxes of Cypress Swamp and Marshes in the Greater Everglades Using Eddy Covariance Measurements and Landsat Data. *Remote Sens. Environ.* **2021**, *262*, 112523. [[CrossRef](#)]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.