

**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CÂMPUS JABOTICABAL**

**MODELAGEM COMPUTACIONAL DA CONCENTRAÇÃO ATMOSFÉRICA
DE CO₂ e CH₄ NO BRASIL CENTRAL**

Pedro Henrique Marucio de Oliveira

Jaboticabal - SP

**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CÂMPUS DE JABOTICABAL**

**MODELAGEM COMPUTACIONAL DA CONCENTRAÇÃO ATMOSFÉRICA
DE CO₂ e CH₄ NO BRASIL CENTRAL**

Pedro Henrique Marucio de Oliveira

Orientador: Prof. Dr. Alan Rodrigo Panosso

Coorientador: Me. Luís Miguel da Costa

Trabalho de Conclusão de Curso
apresentado à Faculdade de
Ciências Agrárias e Veterinárias –
Unesp, Câmpus de Jaboticabal,
como parte das exigências para a
Graduação em Engenharia
Agrônômica.

Jaboticabal

1º Semestre/2026

O48m

Oliveira, Pedro Henrique Marucio de

Modelagem computacional da concentração atmosférica de CO₂ e CH₄ no
Brasil Central / Pedro Henrique Marucio de Oliveira. -- Jaboticabal, 2026
86 p. : il., tabs., mapas

Trabalho de conclusão de curso (Bacharelado - Engenharia Agrônômica) -
Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e
Veterinárias, Jaboticabal

Orientador: Alan Rodrigo Panosso

Coorientador: Luís Miguel da Costa

1. Ciência do solo. 2. Mudanças climáticas. 3. Análise estatística. 4.
Sensoriamento remoto. 5. Efeito estufa (Atmosfera). I. Título.

CERTIFICADO DE APROVAÇÃO



Pedro Henrique Marucio de Oliveira

MODELAGEM COMPUTACIONAL DA CONCENTRAÇÃO ATMOSFÉRICA DE CO₂ e CH₄ NO BRASIL CENTRAL

Trabalho de Conclusão de Curso apresentado à Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, para obtenção do título de Bacharel em **Engenharia Agrônômica**.

Orientador: Prof. Dr. Alan Rodrigo Panosso

Coorientador (se houver): Mestre Luis Miguel da Costa

Área de Concentração: Ciência do solo

Trabalho aprovado em 29/05/2026

Banca Examinadora:

Documento assinado digitalmente
 **ALAN RODRIGO PANOSSO**
Data: 09/06/2026 09:10:16-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Alan Rodrigo Panosso
UNESP - Faculdade de Ciências Agrárias e Veterinárias - Campus de Jaboticabal

Documento assinado digitalmente
 **NEWTON LA SCALA JUNIOR**
Data: 10/06/2026 13:50:25-0300
Verifique em <https://validar.itl.gov.br>

Dr. Newton La Scala Junior
UNESP - Faculdade de Ciências Agrárias e Veterinárias - Campus de Jaboticabal

Documento assinado digitalmente
 **RODRIGO BARATIERE PERIM**
Data: 10/06/2026 10:44:21-0300
Verifique em <https://validar.itl.gov.br>

Eng. Agr. Rodrigo Baratiere Perim
UNESP - Faculdade de Ciências Agrárias e Veterinárias - Campus de Jaboticabal

Documento assinado digitalmente
 **GLAUCO DE SOUZA ROLIM**
Data: 15/06/2026 20:00:42-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Glaucio de Souza Rolim
Chefe do Departamento

DADOS CURRICULARES DO AUTOR

PEDRO HENRIQUE MARUCIO DE OLIVEIRA – Nascido no município de Matão, São Paulo, no dia 05 de maio de 2004, filho de Santino Rodrigues de Oliveira e Eliane Aparecida Marucio e irmão de Jeovanna Aparecida Marucio de Oliveira. cursando graduação em Engenharia Agrônoma, pela Faculdade de Ciências Agrárias e Veterinárias da Universidade Estadual Paulista (FCAV-UNESP), Campus de Jaboticabal, entre janeiro de 2022 e dezembro de 2026. Durante este período foi bolsista de Iniciação Científica pelo Programa Institucional de Bolsas de Iniciação Científica (PIBIC) e pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), no qual desenvolveu pesquisas relacionadas às áreas de estatística e geoestatística, adquirindo conhecimento sobre as mudanças climáticas, ciência do solo, programação em linguagem R, de processamento, ciência e análise de dados, além de noções sobre sensoriamento remoto. Como forma de divulgação científica, apresentou o trabalho intitulado “*Modelagem computacional da concentração atmosférica de CO₂ e CH₄ no Brasil Central*”, em 2025, financiado pela FAPESP, pelo processo 2024/12884-5, no Simpósio Nacional de Instrumentação Agropecuária, no Campo Experimental em Automação Agropecuária, da Embrapa Instrumentação, em São Carlos. Da mesma forma, apresentou o trabalho intitulado “*Variabilidade espaço-temporal da emissão de gases de efeito estufa e sua relação com a pecuária no Brasil*”, em 2024, financiado pelo CNPq por meio do PIBIC no XXXVI Congresso de Iniciação da Unesp. No mesmo ano, participou do Grupo de Integração Empresa Universidade (GIEU), como parte da divisão de marketing, também participou da origem do Grupo de Estudos em Estatística Computacional Aplicada (GEECA), da UNESP-FCAV. Iniciou monitoria voluntária na disciplina de Estatística e Informática em fevereiro de 2026, ministrada pelo docente Prof. Dr. Alan Rodrigo Panosso, acompanhando e auxiliando aulas em sala, desenvolvendo plantões de dúvidas e resoluções de listas, entre outras atividades complementares aos horários de aula. Atualmente participa de projetos relacionados ao processamento de dados e desenvolvimento de aplicativos.

DEDICATÓRA E OFERECIMENTO

Em primeiro e especial lugar, dedico este trabalho para a minha família, base física e psicológica, que sustentaram e criaram quem eu sou, tornando todas as **nossas** conquistas, possíveis. Dedico à minha mãe, Eliane Aparecida Marucio, a quem devo e dedico a vida, assim como à minha irmã (tata), Jeovanna Marucio, meu braço direito que sempre me apoiou e ajudou. Mulheres de inestimável valor, a quem compartilho toda minha trajetória e amor, que acompanharam minha luta diária e tornaram tudo isso possível. Dedico a meu pai, Santino Rodrigues de Oliveira, que perdurou e me apoiou em meio aos desafios. À minha namorada Amanda Fernandes, mulher de coração enorme, que sempre me ajudou e fortaleceu meu propósito e dedicação. As palavras e o repertório que possuo são insuficientes para expressar a grandiosidade, o sentimento único e intrínseco, que carrego por eles.

Ofereço este trabalho ao meu grande, humilde e excepcional orientador Prof. Dr. Alan Rodrigo Panosso, que auxiliou, apoiou e agregou conhecimentos durante todo o processo de desenvolvimento deste trabalho e para além dele, quem acreditou no meu potencial, e tornou a minha trajetória enriquecedora.

Ofereço ao meu coorientador Me. Luís Miguel da Costa, pela disposição em auxiliar no desenvolvimento deste trabalho, especialmente durante os desafiadores estágios iniciais da minha jornada. Também ofereço ao Prof. Dr. Newton La Scala Júnior, excelente professor, que esteve presente em ideias inovadoras agregadas ao trabalho. Por fim, à Adriana Takakura, secretária simpática, que sempre esteve disposta a prestar ajuda.

AGRADECIMENTO

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq – Projeto 9897, Edital PIBIC 9/2023) e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP - Processo 2024/12884-5) pelo financiamento à pesquisa, fundamentais para o desenvolvimento deste trabalho.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” – Faculdade de Ciências Agrárias e Veterinárias (Unesp/FCAV), e toda a comunidade acadêmica, por manterem a excelência da universidade.

Ao meu orientador e Prof. Dr. Alan Rodrigo Panosso, por toda a orientação, valiosos conhecimentos compartilhados, que transcendem a sala de aula, e pelo constante incentivo à reflexão e ao aprendizado, fundamentais para o desenvolvimento deste trabalho.

À minha família, por todo suporte e apoio incondicional para a continuidade da minha graduação e deste trabalho, assim como durante e antes toda a minha trajetória de vida.

Aos colegas próximos e amigos que fiz para toda a vida, que me acompanharam durante este ciclo, oferecendo apoio, lazer e criando momentos memoráveis durante a graduação. Destaco meus amigos Wellington e parceiro de pesquisa Luís Felipe, que sempre estiveram presentes e apoiando minha trajetória com humildade. Também agradeço a todos os meus colegas do Grupo de Estudos em Estatística Computacional Aplicada (GEECA), por compartilharem conhecimentos durante o processo.

SUMÁRIO

RESUMO	ix
SUMMARY.....	x
1 INTRODUÇÃO	11
2 REVISÃO DE LITERATURA.....	14
2.1 A relação antrópica e as mudanças climáticas	14
2.2 Relação XCO ₂ e XCH ₄ e os agroecossistemas	14
2.3 Relação queimadas e desmatamento com o XCO ₂ e XCH ₄	16
2.4 Sensoriamento remoto para monitoramento dos GEE	17
2.5 A Climate TRACE	18
2.6 Técnicas de análise	19
3 MATERIAL E MÉTODOS.....	21
3.1 Área de estudo.....	21
3.2 Produtos de sensoriamento remoto XCO ₂ , SIF e XCH ₄	22
3.3 Dados NASA POWER	23
3.4 Produtos do MODIS-TERRA do AppEARS.....	23
3.5 Relatórios Climate TRACE	24
3.6 PRODES e DETER - Dados de desmatamento e focos de queimadas	26
3.7 Aquisição, tratamento e processamento dos dados	27
3.8 Estatística descritiva e geoestatística	31
3.9 Remoção da tendência e cálculo da anomalia	33
3.10 Análise exploratória multivariada.....	34
4 RESULTADOS E DISCUSSÕES	38
4.1 Estatística Descritiva	38
4.2 Análise da variabilidade espacial	40
4.3 Análise de correlação linear	43
4.4 Padrões espaciais de XCO ₂ , XCH ₄ e anomalias	45
4.5 Análise das componentes principais (ACP).....	48
4.6 Ano 2015.....	50
4.7 Ano 2016.....	53
4.8 Ano 2017.....	56

4.9	Ano 2018.....	59
4.10	Ano 2019.....	62
4.11	Ano 2020.....	65
4.12	Ano 2021.....	68
4.13	Ano 2022.....	71
4.14	Ano 2023.....	73
5	CONCLUSÕES	77
	LITERATURA CITADA.....	79

RESUMO

As mudanças climáticas são uma preocupação mundial, sendo a principal causa o aumento da concentração de gases de efeito estufa (GEE) na atmosfera, especialmente o dióxido de carbono (CO_2) e o metano (CH_4). Visando sua mitigação, é fundamental compreender a dinâmica desses gases na atmosfera e estabelecer relações com outras variáveis associadas ao sistema solo-planta-atmosfera. Nesse sentido, o objetivo deste trabalho foi descrever a variabilidade espaço-temporal das concentrações atmosféricas de CO_2 e CH_4 nos municípios do Brasil Central, ao longo dos anos de 2015 a 2023, bem como suas relações com índices vegetativos e climáticos. Foram adquiridos dados das concentrações atmosféricas de CO_2 (XCO_2), Fluorescência da Clorofila Induzida pelo Sol (SIF) e CH_4 (XCH_4), variáveis climáticas e vegetativas, informações sobre desmatamento e queimadas e dados dos setores emissores de GEE. Sistematizou-se essa aquisição para redução das diferenças entre as resoluções espaciais dos dados de sensoriamento remoto, com posterior remoção da tendência mundial de XCO_2 e XCH_4 e cálculo da anomalia. Para exploração dos dados, foram utilizadas técnicas exploratórias multivariadas e análise geoestatística, em linguagem R. A interrelação entre as variáveis foi descrita por meio de reconhecimento de padrão, que incluíram análises de correlação, de agrupamento hierárquico e análise de componentes principais. Como resultados, foram gerados os mapas de anomalias, observando-se áreas atuando tanto como fontes líquidas de emissão, quanto remoção líquida de CO_2 e CH_4 . Os valores de anomalia obtidos para CO_2 e CH_4 foram em ordem e respectivamente de 6 ppm e 30 ppb enquanto para remoção, de -2,50 ppm e -20 ppb, médias no período estudado. Para a anomalia de XCO_2 observou-se maiores correlações com a anomalia de XCH_4 a partir do ano de 2020, possivelmente causada pela intensificação dos desmatamentos e queimadas. Enquanto para a anomalia de XCH_4 , foram obtidas maiores correlações com o desmatamento e a queimada, velocidade do vento, radiação solar e Índice de Área Foliar (LAI). Os valores de correlação obtidos para a anomalia de XCH_4 ($r \sim 0,30$) sugerem que as variáveis vegetativas ($r \sim 0,30$) e climáticas ($r \sim \pm 0,40$), o desmatamento ($r = 0,26$) e as queimadas ($r = 0,28$) são relevantes na explicação da variabilidade de XCH_4 . Desse modo, as técnicas geoestatísticas descreveram a variabilidade espaço-temporal da dinâmica de GEE no Brasil central, sendo o melhor modelo ajustado, o exponencial, para XCO_2 e XCH_4 . Os alcances dos semivariogramas de XCO_2 e SIF, foram próximos de 39 km, indicando uma dependência espacial relevante dessas variáveis. A abordagem aprimora a compreensão da dinâmica dos GEE e suas interações com variáveis climáticas e de uso da terra no Brasil Central, fornecendo subsídio para políticas públicas de mitigação das emissões, contribuindo para estratégias de mitigação das mudanças climáticas.

Palavras-chave: efeito estufa adicional, mudanças climáticas, sensoriamento remoto, ciclo do carbono.

Computational Modeling of Atmospheric Concentration of CO₂ and CH₄ in Central Brazil

SUMMARY

Climate change is a global concern, being the main cause of the increased concentration of greenhouse gases (GHG) in the atmosphere, especially carbon dioxide (CO₂) and methane (CH₄). To mitigate this, it is fundamental to understand the dynamics of these gases in the atmosphere and establish relationships with other variables associated with the soil-plant-atmosphere system. In this sense, the objective of this work was to describe the spatiotemporal variability of atmospheric concentrations of CO₂ and CH₄ in municipalities of Central Brazil, throughout the years 2015 to 2023, as well as their relationships with vegetative and climatic indices. Data on atmospheric concentrations of CO₂ (XCO₂), Sun-Induced Chlorophyll Fluorescence (SIF) and CH₄ (XCH₄), climatic and vegetative variations, information on deforestation and wildfires, and data from GHG emitting sectors were acquired. This acquisition was systematized to reduce differences between the spatial resolutions of remote sensing data, with subsequent removal of the global trend of XCO₂ and XCH₄ and calculation of the anomaly. For data exploration, multivariate exploratory techniques and geostatistical analysis were used in R. The interrelationship between variables was described through pattern recognition, which included visualization analyses, hierarchical clustering, and principal component analysis. As a result, anomaly maps were generated, observing existing areas both as net sources of emission and net removal of CO₂ and CH₄. The anomaly values detected for CO₂ and CH₄ were, respectively, 6 ppm and 30 ppb, while for removal, they were -2.50 ppm and -20 ppb, averages over the tested period. For the XCO₂ anomaly, the highest correlations with the XCH₄ anomaly were observed from the year 2020 onwards, possibly caused by the intensification of deforestation and fires. While for the XCH₄ anomaly, there were stronger correlations with deforestation and burning, wind speed, solar radiation, and Leaf Area Index (LAI). The evidence values obtained for the XCH₄ anomaly ($r \sim 0.30$) suggest that vegetative ($r \sim 0.30$) and climatic ($r \sim \pm 0.40$) variables, deforestation ($r = 0.26$), and burning ($r = 0.28$) are relevant in explaining the variability of XCH₄. Thus, geostatistical techniques described the spatiotemporal variability of GHG dynamics in central Brazil, with the exponential model being the best fitted for XCO₂ and XCH₄. The ranges of the semivariograms of XCO₂ and SIF were close to 39 km, showing a relevant spatial dependence of these variables. The approach, which enhances the understanding of GHG dynamics and their interactions with climatic and land-use variables in Central Brazil, provides input for public policies on emission mitigation, contributing to climate change mitigation strategies.

Keywords: additional greenhouse effect, climate change, remote sensing, carbon cycle.

1 INTRODUÇÃO

As mudanças climáticas são um tema de grande importância em âmbito mundial e a sua principal causa é o aumento da concentração atmosférica de gases de efeito estufa (GEE), especialmente o dióxido de carbono (CO_2), o óxido nitroso (N_2O) e o metano (CH_4). Essas mudanças correspondem a alterações de longo prazo nos padrões climáticos, intensificadas principalmente por atividades humanas, resultando no aquecimento global, eventos extremos mais frequentes, elevação do nível do mar e mudanças nos ecossistemas (IPPC, 2023; Cheng et al, 2026).

O aumento da concentração de GEE é causado principalmente pela emissão de CO_2 proveniente da queima de combustíveis fósseis (Hedelius et al., 2018). Entretanto, no Brasil, quando considerado as mudanças no uso e ocupação do solo para expansão agrícola, o setor agropecuário é responsável por 74% das emissões totais de GEE (De Azevedo et al., 2018; Potenza et al., 2023). Contudo, a agricultura pode contribuir para mitigação do CO_2 , sequestrando-o da atmosfera e acumulando-o na forma de biomassa vegetal e no solo (Funk et al., 2015; Vieira; Lunas; Lemes, 2025).

A região Centro-Oeste do Brasil apresenta um Produto Interno Bruto (PIB) de aproximadamente 10,34% do PIB nacional (IBGE, 2021), contando com um setor agropecuário e polo agrícola de grande destaque no país, enquadrando-o como maior exportador mundial de soja e carne bovina. Essa produção está distribuída predominantemente pelos estados da região central, como Mato Grosso (MT), Goiás (GO) e Mato Grosso do Sul (MS) (IBGE, 2024). Esse cenário evidencia o alto potencial de mitigação dos impactos climáticos nesses estados.

Estimar os impactos climáticos de tais sistemas de produção é um desafio, dada a multiplicidade de variáveis e suas interações. Nesse sentido, diante da necessidade global para compreender a dinâmica dos GEE, minimizar incertezas e identificar possíveis fontes e sumidouros desses gases, missões espaciais são desenvolvidas com o objetivo de monitorá-los (Ambrizzi et al., 2014). Dentre essas a *Greenhouse Gases Observing Satellite* (GOSAT), que busca estimar as concentrações atmosféricas de CH_4 (XCH_4), e o sensor orbital *Orbiting Carbon Observatory-2* (OCO-2), que objetiva monitorar e disponibilizar observações da coluna-média de CO_2 atmosférico (XCO_2 - Crisp et al., 2017). Técnicas de análise de dados têm sido empregadas no desenvolvimento de modelos preditivos para diversas variáveis do sistema solo-planta-atmosfera (McBratney et al., 2000; Reichstein et al., 2019), permitindo superar desafios estatísticos impostos pelo número crescente de covariáveis ambientais. Apesar de tais esforços e ampla cobertura, carecem estudos que avaliam a forma com as quais variáveis como a respiração heterotrófica do solo, a absorção de CO_2 pela vegetação, a ocorrência de fogo e desmatamentos influenciam os padrões espaço-temporais de XCO_2 e XCH_4 no Brasil Central.

Nesse sentido, a hipótese deste trabalho se baseia em como as mudanças na respiração heterotrófica do solo, na absorção de CO_2 pela vegetação, e a ocorrência de focos de fogo e desmatamentos resultam em anomalias espaciais e temporais nos níveis de XCO_2 e XCH_4 na atmosfera do Brasil Central. Essas anomalias, que refletem a dinâmica das interações entre o solo, as plantas e a atmosfera, podem ser identificadas e quantificadas utilizando técnicas avançadas de análise de dados.

Sendo assim, o **objetivo** do trabalho foi analisar a variabilidade espaço-temporal das concentrações atmosféricas de CO₂ e CH₄ em áreas do Brasil Central, identificando fontes e possíveis sumidouros desses gases ao longo dos anos de 2015 a 2023, bem como suas relações com índices vegetativos e climáticos, por meio de dados do GOSAT, OCO-2, NASA POWER, Climate TRACE, DETER, PRODES e AppEEARS.

2 REVISÃO DE LITERATURA

2.1 A relação antrópica e as mudanças climáticas

As mudanças climáticas representam um tema relevante em âmbito mundial e a sua principal causa é o aumento da concentração atmosférica de gases de efeito estufa (GEE), especialmente o dióxido de carbono (CO_2), o óxido nitroso (N_2O) e o metano (CH_4). Esse aumento é bem estabelecido e atribuído principalmente às atividades humanas, além dos fatores naturais, desde o século XIX (IPCC, 2023; Hoogendoorn; Sütterlin; Siegrist, 2020). Desde a década de 1970, as evidências científicas evoluíram de uma hipótese, para a comprovação inequívoca da influência humana no aquecimento do sistema climático (IPCC, 2021).

Os fatores naturais que influenciam as mudanças climáticas apresentam menor impacto no aumento da temperatura global quando comparados às atividades antrópicas (IPCC, 2023; IPCC 2021; Hansen; Stone, 2016). De acordo com o IPCC (2023), o impacto humano foi responsável por um aumento de aproximadamente $1,07\text{ }^\circ\text{C}$ em relação aos níveis pré-industriais, enquanto o forçamento natural contribuiu com apenas cerca de $\pm 0,1\text{ }^\circ\text{C}$. Conforme descrito pelo último relatório, os níveis atuais de GEE na atmosfera expõem a incapacidade humana de reduzir seu impacto no clima (IPCC, 2022).

2.2 Relação XCO_2 e XCH_4 e os agroecossistemas

Atualmente, a concentração atmosférica de dióxido de carbono (CO_2) atingiu 423 ppm, representando um aumento de cerca de 1,5 vezes em relação aos níveis pré-industriais, enquanto o metano (CH_4) cerca de 1930 ppb em 2024,

2,6 vezes os níveis pré-industriais (WMO, 2025; EEA, 2025). Além dos níveis atmosféricos elevados, o metano tem um potencial de aquecimento 28 vezes maior (100 anos) que o CO₂. De acordo com o sexto relatório de avaliação (AR6) do IPPC, apesar do menor tempo de permanência (cerca de 10 anos), o metano contribuiu com aproximadamente 16% (0,54 W m⁻²) do forçamento radiativo efetivo total entre os GEE desde 1750, período pré-industrial. Os reflexos e impactos das mudanças climáticas são evidenciados no mundo todo e em diversos setores, como o econômico, ambiental e social (IPPC, 2023; Santos; Oliveira; Ferreira Filho, 2022; Ribeiro, 2008).

De acordo com Potenza et al. (2023), o setor agropecuário brasileiro é responsável por 74% das emissões totais de GEE quando em conjunto com o de Mudança de uso da terra e florestas (MUT). Contudo, deve-se ressaltar que a agricultura contribui positivamente para mitigação do CO₂, sequestrando-o da atmosfera e acumulando-o na forma de biomassa vegetal e no solo, especialmente se práticas de manejo adequadas são utilizadas (Funk et al., 2015). Além disso, estimativas indicam que em 2030, se o Plano de Agricultura de Baixo Carbono (ABC) atingir todas as metas de implementação, o potencial de mitigação de GEE do país poderá ser de 1100 Mt CO₂ equivalente (SEEG, 2021).

Segundo os dados divulgados pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2021) a região Centro-Oeste apresenta um Produto Interno Bruto (PIB) de aproximadamente 10,34% do PIB nacional. Essa região apresenta o setor agropecuário de grande destaque no país, sendo um importante polo agrícola do país, especialmente para a cultura da soja, com

cerca de 46% da produção nacional, e produção de carne bovina, com cerca de 46% do volume das exportações (Conab, 2024; ABIEC, 2025). O Brasil apresenta destaque mundial como um dos maiores produtores e o maior exportador de carne bovina, responsável por uma produção de 11.900 mil toneladas em 2025, representando 19,34% do volume global produzido e exportação de 2.764 mil toneladas (USDA, 2025; ABIEC, 2025). Esse cenário evidencia a importância de adoção de sistemas de produção conservacionistas e investimentos em inovações, à medida que o mercado internacional intensifica a demanda por produtos com origem sustentável, cresce a valorização econômica desses itens (Pinheiro; Nise; Sobrinho, 2025). Ademais, contando com o maior rebanho bovino comercial do mundo, o Brasil contabiliza mais de 238 milhões de cabeças de gado. Essa quantidade está distribuída principalmente pelos estados da região central do país, como Mato Grosso (MT), ocupando a primeira posição, seguido por Goiás (GO) ocupando a terceira e Mato Grosso do Sul (MS), na quinta, com rebanhos aproximados de 32,85; 23,21 e 18,74 milhões de cabeças, respectivamente (IBGE, 2024). Esses e outros índices evidenciam o importante desempenho da agropecuária no país, especialmente nessa região, sendo uma área com grande potencial para redução das atuais emissões dos GEE e valorização sustentável e econômica desse grande setor (FAOSTAT, 2024; USDA, 2024).

2.3 Relação queimadas e desmatamento com o XCO_2 e XCH_4

A ocorrência de focos de fogo resultam em anomalias espaciais e temporais nos níveis de XCO_2 e XCH_4 na atmosfera do Brasil Central, mas não

só desta região (Silva Junior et al., 2022; Ferreira Barbosa et al., 2022). Investigando a variabilidade espaço-temporal nas observações do XCH_4 , em estudo conduzido no bioma Amazônia, de Maria et al. (2023) observaram que a distribuição espacial do XCH_4 expressa forte correlação entre o XCH_4 e a anomalia XCO_2 , assim como sua distribuição temporal demonstra significativa relação com as variáveis climáticas umidade e temperatura da superfície terrestre. Com ambas as relações observadas especialmente em períodos secos, associadas ao maior número de focos de incêndio (Silva Junior et al., 2022).

De maneira semelhante, a ocorrência de desmatamentos resulta em anomalias espaço-temporais nos níveis de XCO_2 e XCH_4 . No Brasil, as emissões de CO_2 estão principalmente ligadas a mudanças no uso e cobertura da terra e floresta (De Azevedo et al., 2018). Em países tropicais, as emissões de carbono são geradas em grande parte por processos diretos de desmatamento (Aragão et al., 2018; Lawrence e Vandecar, 2015). O papel das florestas como sumidouro de carbono é reconhecido, de modo que o desmatamento, muitas vezes associados com as queimadas, acabam por intensificar os níveis de XCO_2 e XCH_4 na atmosfera, especialmente no Brasil Central (Da Costa et al., 2024; Garofalo et al., 2022; Gatti et al., 2021; Funk et al., 2015).

2.4 Sensoriamento remoto para monitoramento dos GEE

Diante da necessidade global para compreender a dinâmica dos GEE e identificar possíveis fontes e sumidouros desses gases, missões espaciais têm sido desenvolvidas com o objetivo de monitorá-los (Silva et al., 2026). Dentre essas, a missão GOSAT teve como objetivo avaliar as fontes e sumidouros de

GEE para estimar as concentrações atmosféricas de CH_4 (XCH_4) em escalas regionais e globais. Essa missão tem contribuído para a geração de informações e melhorias na gestão dos recursos ambientais, auxiliando pesquisas voltadas para a compreensão do ciclo global do carbono no ecossistema a partir da observação da sua coluna atmosférica média (Feng et al., 2017). Por sua vez, o sensor orbital *Orbiting Carbon Observatory-2* (OCO-2) foi lançado em 2014 com objetivo de monitorar e disponibilizar observações da coluna-média de CO_2 atmosférico (XCO_2 - Crisp et al., 2017). Devido aos instrumentos embarcados e às características espectrais do satélite, o OCO-2 também é capaz de observar a Fluorescência da Clorofila Induzida pelo Sol (SIF), que tem sido utilizada como aproximação da taxa fotossintética realizada pelas plantas (Frankenberg et al., 2014; Mohammed et al., 2019).

2.5 A Climate TRACE

No ano de 2023, uma nova ferramenta foi disponibilizada: a plataforma Climate TRACE (<https://climatetrace.org/>). Essa plataforma é uma coalizão de organizações dedicadas a aprimorar o monitoramento das emissões de GEE em âmbito global. A iniciativa desenvolveu uma abordagem que combina sensoriamento remoto, técnicas de aprendizado de máquina e dados reportados para estimar as emissões globais de GEE por setor. Seus dados incluem estimativas de emissões para agricultura, operações com combustíveis fósseis, florestas e uso da terra, resíduos, entre outros setores, totalizando 9 setores com um adicional.

2.6 Técnicas de análise

Inúmeras técnicas avançadas de análise de dados têm sido empregadas com sucesso no desenvolvimento de modelos preditivos/explicativos para diversas variáveis pedométricas, 6 climatológicas, ambientais e agrícolas (McBratney et al., 2000; Reichstein et al., 2019; Warner et al., 2019; Shadrin et al., 2020). Como exemplos recentes de aplicação dessas técnicas temos: previsão e mapeamento de vários atributos do solo, como o teor de carbono orgânico e o nitrogênio total (Hengl et al., 2017; Hengl et al., 2018; Heuvelink et al., 2020; Zhou et al., 2020), potencial de sequestro de carbono do solo (Mahmoudzadeh et al., 2020) e estimativas de produtividade de culturas agrícolas (Ferraciolli; Bocca; Rodrigues, 2019; Sanches; Graziano Magalhães; Junqueira Franco, 2019). Em adição, muitos estudos têm sido conduzidos para analisar e compreender a relação entre a emissão de GEE e o aumento da temperatura global por meio de técnicas de aprendizado de máquina, pois essas oferecem grande potencial para refinar as estimativas do ciclo de carbono em escala global (Reichstein et al., 2019). Essas técnicas permitem superar os desafios estatísticos impostos por um número cada vez maior de covariáveis ambientais espacialmente distribuídas. Geralmente, muitas dessas (co)variáveis podem estar correlacionadas entre si ou apresentar relações não lineares, incluindo dependência espacial, violando a importante suposição de dados distribuídos de forma idêntica e independente imposta pela abordagem probabilística (Farhate et al., 2018; Freitas et al., 2018; Reichstein et al., 2019; Warner et al., 2019). Apesar de todos os esforços, ainda são poucos os trabalhos que estudam de que forma variáveis como a respiração heterotrófica do solo, a

absorção de CO_2 pela vegetação e a ocorrência de fogo influenciam os padrões espaço-temporais de XCO_2 e XCH_4 no Brasil Central.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

As análises foram conduzidas nos estados pertencentes à região Centro-Oeste do Brasil, Goiás (GO), Mato Grosso (MT) e Mato Grosso do Sul (MS). Esses estados abrangem, respectivamente, áreas territoriais aproximadas de 340; 903 e 357 mil km², totalizando cerca de 1,6 milhões de km² (cerca de 19% do território brasileiro), além de contarem com 246, 141 e 79 municípios, respectivamente, totalizando 466 municípios e o Distrito Federal (DF). Esses estados situam-se predominantemente nos biomas Cerrado (CER), Pantanal (PNT) e Amazônia (AMZ), com uma pequena região de Mata Atlântica (MAT) ao Sul do MS (IBGE, 2024; IBGE, 2019). É possível visualizá-los conforme apresentado no mapa de localização (Figura 1).




Figura 1. Mapa de localização dos estados do Brasil Central e seus biomas.

Segundo a classificação de Köppen (Alvares *et al.*, 2013), o clima predominante na região, é o Tropical de Savana (Aw), caracterizado por verões quentes e chuvosos e invernos secos. A região apresenta também áreas com clima Tropical Monçônico (Am), caracterizado por chuvas intensas e uma estação seca menos pronunciada, ao norte do MT e em grande parte da área central do MS, além de pequenas áreas de Clima Subtropical Úmido (Cfa) e Clima Equatorial Úmido (Af) ao Sul do MS (Da Silva Filho *et al.*, 2021).

3.2 Produtos de sensoriamento remoto XCO₂, SIF e XCH₄

Os dados de concentração da coluna média de CO₂ atmosférico (XCO₂) e fluorescência de clorofila induzida pelo sol (SIF) foram obtidos do satélite OCO-2. A SIF utilizada foi a do comprimento de onda de 757 nm devido sua forte correlação com índices de vegetação do sensor MODIS (Doughty *et al.*, 2022; LI; XIAO; HE, 2018). Os sensores do satélite OCO-2 apresentam resolução espacial menor que 3 km² (2,25 km x 1,29 km), com as duas missões realizando uma cobertura por todo o território brasileiro em um período de revisita de 16 dias. Utilizou-se dados da versão 11.1r do Nível 2 do OCO-2 Level 2 bias-corrected XCO₂ (disponível em: https://disc.gsfc.nasa.gov/datasets/OCO2_L2_Lite_FP_11.1r/summary) e a 10.4r do OCO-3 (https://disc.gsfc.nasa.gov/datasets/OCO3_L2_Lite_FP_10.4r/summary?keyword=oco3).

Os dados de concentração de CH₄ atmosférico (XCH₄) foram obtidos a partir do satélite GOSAT. O GOSAT permite uma revisita ao mesmo local em

períodos de 3 dias (resolução temporal), possuindo uma cobertura espacial de aproximadamente 10 km, em pixels circulares separados por cerca de 270 km. Os dados de XCH₄ foram obtidos da versão 9.0 da Universidade de Leicester GOSAT Proxy (https://data.ceda.ac.uk/neodc/gosat/data/ch4/nceov1.0/CH4_GOS_OCPR/), em formato .nc (Parker; Boesch, 2020).

3.3 Dados NASA POWER

Os dados da NASA POWER (<https://power.larc.nasa.gov>) foram requisitados via Interface de Programação de Aplicações (do inglês *Application Programming Interface* - API). Essa plataforma da NASA é composta pelo projeto intitulado: Previsão Dos Recursos Energéticos Mundiais (do inglês, *Worldwide Energy Resource Forecast* - POWER) e foi iniciado para aprimorar o conjunto de dados de energia renovável atual e criar conjuntos de dados a partir de novos sistemas de satélites (Stackhouse *et al.*, 2015). A partir dela foram adquiridos os dados das **variáveis climáticas** precipitação (mm), radiação solar de onda curta na superfície (MJ m⁻² dia⁻¹), Temperatura média do ar a 2 m (°C), umidade relativa a 2 m (%), velocidade do vento a 2 m (m s⁻¹) e pressão de superfície (kPa), abrangendo todo o Brasil e o período de 2015 a 2023.

3.4 Produtos do MODIS-TERRA do AppEEARS

O AppEEARS (*Application for Extracting and Exploring Analysis Ready Samples*) é uma plataforma da NASA desenvolvida pela Land Processes Distributed Active Archive Center (LP DAAC) que facilita o acesso e o pré-

processamento de dados de sensoriamento remoto, especialmente da coleção do sensor MODIS e outros produtos de observação da Terra, fornecendo-se, conjuntamente, valores de dados de qualidade associados. Dois tipos de solicitações de amostra estão disponíveis: amostras pontuais por coordenadas geográficas e amostras de áreas espaciais por meio de polígonos vetoriais (AppEEARS Team, 2024).

Para esta base, em razão do limite de solicitação, foram solicitadas amostras pontuais em 2 requisições. Essas amostras foram obtidas para as coordenadas geográficas dos municípios do Brasil Central mais próximas às dos relatórios *Climate TRACE* (cerca de 1150 coordenadas). As **variáveis vegetativas** requisitadas foram: Radiação Fotossinteticamente Ativa (do inglês *Fraction of photossynthetically active radation* - Fpar), Índice de Área Foliar (*Leaf Area Index* – LAI), Evapotranspiração Total (*Total Evapotranspiration* - TE) e índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (*Normallized Difference Vegetation Index* - NDVI) e Índice de Vegetação Aprimorado (*Ennhaced Vegetation Index* - EVI), todas do sensor MODIS a bordo do satélite TERRA e para o período de 2015 a 2023, com exceção à ET, em que se inicia a partir do ano de 2021.

3.5 Relatórios Climate TRACE

A *Climate TRACE* (*Tracking Real-time Atmospheric Carbon Emissions*) monitora as emissões de gases de efeito estufa globalmente por setor por meio de uma abordagem híbrida de técnicas inovadoras, como aprendizado de máquina e inteligência artificial associados às diretrizes do IPCC. A *Climate*

TRACE fornece dados para nove setores: Manufatura, Agricultura, Edificações, Operações de Combustíveis Fósseis, Extração Mineral, Transporte, Resíduos, Energia e Uso da Terra e Florestas, além de uma estimativa adicional de gases fluorados. Cada um desses setores tem seu próprio método para contabilizar as emissões e, especificamente no setor de Uso da Terra e Florestas, para contabilizar as remoções. O setor agrícola contabiliza as emissões na fermentação entérica de bovinos e manejo de esterco, cultivo de arroz e fertilizante sintético e o setor de Uso da Terra e Florestas contabiliza as emissões de reservatórios de água e de florestas, pastagens, manguezais e áreas úmidas. Cada um desses processos possui fonte de dados própria e metodologia que pode combinar dados relatados com dados de satélite, e as estimativas são feitas por meio de fatores de emissão e modelos de aprendizado de máquina. As descrições metodológicas atual de cada uma delas podem ser encontradas no seguinte endereço eletrônico a seguir: <https://github.com/climatetracecoalition/methodology-documents>.

Os dados das emissões foram adquiridos dos relatórios disponíveis na plataforma CT (<https://climatetrace.org>) e adquiridos para anos diferentes. No ano de 2023, para o período de 2015 a 2020, e no ano de 2025, de 2021 a 2024, em formato .csv. Essa aquisição foi devido a atualização da plataforma e, com isso, aqueles anteriores a 2021, que incluíam as estimativas mensais de emissão de GEE, deixaram de estar disponíveis para consulta. Esses documentos só podem ser acessados caso tenham sido previamente salvos no disco local do computador, podendo ser solicitados ao autor deste artigo. Desse modo, para a condução das análises foram coletados conjuntos de dados sobre as emissões

de GEE e potenciais fontes emissoras destes para todos os setores do Brasil, compreendendo o período de 2015 a 2024.

3.6 PRODES e DETER - Dados de desmatamento e focos de queimadas

Os dados de desmatamento e focos de queimadas foram adquiridos pela plataforma TerraBrasilis (<https://terrabrasilis.dpi.inpe.br/downloads/>), desenvolvida pelo Instituto Nacional de Pesquisas Espaciais (INPE). Referente aos dados de desmatamento, estes foram adquiridos dos mapas das classes do Programa de Monitoramento da Amazônia Legal por Satélite (PRODES) para todo o Brasil e por biomas, para o período do dia 31 de julho de 2000 a 30 de julho de 2023, em formato matricial Geotiff. O PRODES considera como desmatamento a supressão da vegetação nativa, independentemente da futura utilização destas áreas. Esse programa é uma iniciativa governamental que realiza o inventário de perda da cobertura florestal primária desde 1988, a partir de uma metodologia incremental, mapeando anualmente os desmatamentos na região da Amazônia Legal Brasileira (ALB), sendo fundamental para avaliar as mudanças no uso da terra, uma das principais fontes históricas de emissões de gases de efeito estufa no país (SEEG, 2018; SEEG, 2025). Esse programa é responsável por realizar o monitoramento por meio de imagens de satélites da classe LANDSAT (LANDSAT-8 e LANDSAT-9), SENTINEL-2 e CBERS-4/4A, identificando polígonos de desmatamento com área superior a 1 ha ou, 6,25 para Amazônia, apresentando resolução espacial na faixa de 20-30 metros, taxa de revisita entre 5 e 26 dias e pelo menos três bandas espectrais, com precisão em torno de 95% (Almeida *et al.*, 2022). Os dados de desmatamento foram calculados com base na intensidade de ocorrência dentro de cada município em

determinado ano, atribuindo-se a cada cidade um valor proporcional ao número de eventos registrados em relação ao total de ocorrências observadas naquele ano.

O Sistema de Detecção de Desmatamento em Tempo Real (DETER), apresenta capacidade de monitorar com grande resolução e precisão os incêndios e focos de calor. Este sistema se utiliza de imagens do sensor WFI, a bordo dos satélites CBERS-4, 4A e Amazônia-1/INPE. Essas imagens são captadas pelo sensor em quatro bandas espectrais (azul, verde, vermelho e infravermelho próximo), apresentam resolução espacial entre 56-64 metros e uma taxa de revisita combinada de um ou dois dias (Almeida *et al.*, 2022). Os dados do DETER foram adquiridos para a Amazônia, Pantanal e Cerrado, em formato *shapefile*. No entanto, somente o bioma Amazônia e Pantanal contém os dados de focos de queimadas do DETER disponibilizados para os estados do Brasil Central. Os dados referentes à Amazônia abrangem o período de 2016 a janeiro de 2023, enquanto para o Pantanal a série tem início somente a partir de agosto de 2023. Em ambos os casos, foram considerados os produtos provenientes do satélite de referência *Landsat*, além de sensores similares como Amazônia-1 e CBERS-4. O DETER produz diariamente avisos de alteração na vegetação, como para áreas em processo de degradação florestal, como exemplo as queimadas, maiores ou iguais a 3 hectares.

3.7 Aquisição, tratamento e processamento dos dados

Em resumo, os produtos de mapeamento digital adquiridos foram relativos ao XCO₂ e à SIF do sensor orbital do OCO-2 – o XCH₄ do satélite GOSAT – às variáveis climáticas do *NASA POWER* – às variáveis vegetativas do AppEEARS

– ao desmatamento e às queimadas da plataforma TerraBrasilis dos programas PRODES e DETER, respectivamente – e aos relatórios de emissão de gases de efeitos estufa (GEE) da *Climate TRACE*. As variáveis e suas unidades, os sensores e suas plataformas, e as resoluções temporais e espaciais dos satélites correspondentes foram simplificados na Tabela 1, enquanto os dados compilados em uma única base são demonstrados de forma resumida na Tabela 2.

Para a região em questão, os dados foram obtidos para o período de 2015 a 2023, com exceção dos dados de evapotranspiração total e XCH_4 (tal exceção foi criteriosamente avaliada). Os dados de XCH_4 estão disponíveis somente até o ano de 2021, assim, para possibilitar as análises, realizou-se a predição dos valores para 2022 e 2023 por meio do método de regressão linear simples, utilizando como base de treinamento os dados observados no período de 2015 a 2021. Desse modo, uma boa prática para análises futuras seria utilizar-se do conjunto de dados de XCH_4 obtido pela Universidade de Leicester desde que estejam atualizados, ou mesmo, substituí-los por dados de XCH_4 de sensores como o TROPOMI do satélite Sentinel-5P, para melhoria dos resultados (Reshi; Pichuka; Tripathi, 2024).

Tabela 1. Variáveis estudadas, sensores e plataformas, resoluções temporais e espaciais.

	Variável (unidade)	Base de dados	Res. temporal	Res. Espacial
CO ₂	XCO ₂ ppm	OCO-2	16 dias	2.25 km × 1.29 km
CH ₄	XCH ₄ (ppb)	GOSAT	3 dias	10 km × 10 km
CLIMA	Precipitação (mm)	NASA POWER	Diária	55,6 km
	Radiação ondas curtas (MJ m ⁻² day ⁻¹)			
	Temperatura (°C)			
	Umidade relativa (%)			
	Velocidade do vento (m s ⁻¹)			
	Pressão da superfície (kPa)			
VEGETATIVA	SIF (W m ⁻² sr ⁻¹ μm ⁻¹)	OCO-2	16 dias	2,25 km × 1,29 km
	FPAR (%)	AppEEARS (MODIS-TERRA)	8 dias	500 m × 500 m
	LAI (m ² m ⁻²)			
	ET (Kg m ⁻² 8 ⁻¹ day ⁻¹)			
	EVI			
	NDVI		16 dias	250 m × 250 m
DMT	Intensidade de ocorrência (%)	DETER PRODES	5-26 dias	20-30 m
QMD	Área (km ²)		1-2 dias	56-64 m

DMT: Desmatamento e QMD: Área queimada

Tabela 2. Visualização simplificada da base completa, cobrindo um ano do período, região, algumas variáveis, setores e subsetores.

anos	estado	município	temp	sif	XCH ₄	XCO ₂	QMD	DMT	ndvi	set	subset
2021	GO	baliza	25,5	0,3	1878,3	411,4	0,3	0,2	0,6	X	X
2021	MS	terenos	25,8	0,4	1869,2	414,3	0,5	0,1	0,6	X	X
2021	MT	vera	25,8	0,5	1878,8	414,3	0,3	0,3	0,6	X	X

temp: temperatura média; QMD: área queimada; DMT: desmatamento percentual; set: setores; subset: subsectores e X: valores médios de emissão do setor/subsetor.

Com o objetivo de reduzir as diferenças entre as resoluções espaciais dos dados de sensoriamento remoto, foi feita uma sistematização da aquisição, onde os dados dos NASA POWER e AppEEARS foram ajustados de acordo com as coordenadas mais próximas dos municípios das observações do OCO-2 e GOSAT (Golkar *et al.*, 2020; da Costa *et al.*, 2023). De modo semelhante foram agregados os dados das observações do *Climate TRACE*. Após download dos dados brutos e implementação em linguagem de programação R (R Development Core Team, 2024), as bases foram tratadas individualmente. Esse tratamento consistiu em extrair e organizar as informações em bancos de dados tabulares, contendo informações das variáveis, períodos, satélites, datas, coordenadas, entre outras.

O processamento teve como objetivo padronizar as informações para possibilitar a incorporação dos dados em uma única base e realizar a estimativa de valores em locais não amostrados por meio da krigagem ordinária (KO). A princípio, priorizou-se a classificação das coordenadas em seu respectivo estado e município para viabilizar as análises regionalizadas. Em seguida, foi feito o agrupamento por data e o cálculo da média das variáveis numéricas por mês e ano para permitir a análise ao longo da série temporal. No entanto, em razão da

ausência de dados de desmatamento por mês, as variáveis foram agrupadas anualmente, de acordo com a média das observações para cada município da área de estudo. Sendo assim, o pré-processamento consistiu em filtragens dos dados para o período de 2015 a 2023, assim como para a região dos estados do Brasil Central, seguido de agrupamentos das coordenadas dos municípios em análise, com granularidade anual. Esse agrupamento teve como objetivo reduzir o tamanho dos conjuntos de dados, além de padronizar as observações entre as diferentes bases. Isso permitiu viabilizar as análises da variabilidade dos GEE, tornando-as mais rápidas e representativas. Posteriormente, todas as bases de dados foram incorporadas em um único conjunto de dados, subdivididos pelo setor e subsetor de emissão, denominado "base_completa_setores" e "base_completa_subsetores" no script (<https://github.com/phedroo/projeto-oliveiraphm>). O resumo da base completa pode ser visualizado na Tabela 2.

3.8 Estatística descritiva e geoestatística

Inicialmente os dados foram submetidos a análises anuais de acordo com a estatística descritiva (média, mediana, variância, desvio padrão, coeficiente de variação, assimetria e curtose, assim como o mínimo e máximo (não apresentados)). Nas próximas etapas, os dados foram analisados de acordo com a geoestatística. A análise geoestatística leva em consideração a localização geográfica e a dependência espacial, avaliando-se essa dependência por meio de ajuste de modelos matemáticos aos semivariogramas experimentais (Camargo, 1998; Vieira *et al.*, 2000). Os semivariogramas (modelo aliado às observações experimentais) são ferramentas da geoestatística com a finalidade de estimar o grau de dependência espacial entre os pontos amostrados, inferindo

sobre a relação de uma variável espacializada (Seidel; Oliveira, 2014). Após a modelagem matemática, a estimativa da variável em locais não amostrados foi realizada pela técnica da krigagem ordinária (KO). Essa técnica permite representar quantitativamente a variação espacial de um fenômeno regionalizado (Dalchiavon *et al.*, 2011) ou no tempo, definido por três parâmetros: o efeito pepita (C_0), o alcance (a) e o patamar ($C_0 + C_1$). O semivariograma experimental pode ser estimado pela seguinte fórmula (Burrough; McDonnell, 1998):

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2, \quad (1)$$

em que: $\hat{\gamma}(h)$ é a estimativa da semivariância na distância de separação h ; N é o número de pares de pontos separados pela distância h ; $Z(x_i)$ é o valor da variável Z no ponto x_i ; $Z(x_i + h)$ é o valor da variável Z no ponto $x_i + h$. O gráfico de $\hat{\gamma}(h)$, em função de h , denomina-se semivariograma experimental, o qual exibe um comportamento puramente aleatório ou sistemático que pode ser descrito por modelos teóricos. Os semivariogramas experimentais foram ajustados pelo método dos mínimos quadrados, a modelos matemáticos teóricos (esférico, exponencial e Gaussiano). A escolha do melhor modelo ajustado aos semivariogramas utilizados no método da KO foi realizada por meio das validações cruzada (*leave one out cross validation* - LOOCV). Em um local não amostrado e para um determinado semivariograma, foi realizada a estimativa em locais não amostrados por meio da krigagem ordinária, considerada a estimativa não viesada e de variância mínima, ou seja, uma média ponderada ótima dos dados vizinhos (Cressie, 1990).

3.9 Remoção da tendência e cálculo da anomalia

Em seguida, os dados da série temporal de XCO_2 e XCH_4 foram submetidos à análise para retirada da tendência pelo método de regressão linear simples, para obtenção do coeficiente angular β_1 de cada município. Essa etapa teve como finalidade remover a tendência de aumento monotônica mundial da concentração de CO_2 e de CH_4 na atmosfera, para que haja um padrão de comparação às tendências de uma determinada região. Para comparar os resultados ao longo dos anos, foi realizada uma análise específica para cada ano (2015-2023). Ademais, para acessar as assinaturas antropogênicas presentes nos dados, utilizou-se metodologia proposta por Hakkarainen *et al.* (2016). Após a retirada da tendência foram calculadas as anomalias para XCO_2 e XCH_4 em cada município.

$$XCO_{2(anom)} = XCO_{2(i,j)} - Me(XCO_{2(j)}) \quad (1)$$

$$XCH_{4(anom)} = XCH_{4(i,j)} - Me(XCH_{4(j)}). \quad (2)$$

Este cálculo consistiu na diferença entre o valor individual de XCO_2 ou XCH_4 registrado pelos satélites e o valor de fundo, aqui definido como a mediana anual de XCO_2 e XCH_4 . A interpretação a partir desta metodologia visa identificar variações locais que possam indicar contribuições antropogênicas ou alterações nas emissões naturais, capturando padrões específicos de emissão. Este método permite uma avaliação detalhada da dinâmica desses gases na atmosfera, fornecendo informações importantes para a gestão de emissões e

para o desenvolvimento de políticas de mitigação (de Souza Maria *et al.*, 2023; Hakkarainen *et al.*, 2016).

3.10 Análise exploratória multivariada

Anteriormente à condução das análises multivariadas, foi realizada a padronização dos dados para que cada variável apresentasse média nula e variância unitária. O objetivo da padronização consistiu em minimizar as dimensões das variáveis de modo a estabelecer o mesmo peso nos cálculos do coeficiente de similaridade entre os pontos amostrais (os municípios). Ou seja, a não-padronização poderia levar a inconsistências nas soluções das técnicas aqui aplicadas, uma vez que a maioria das medidas de distância, como a Euclidiana, aqui utilizada, são sensíveis às diferentes escalas ou magnitudes das variáveis (Hair *et al.*, 2005). Isso permite comparar adequadamente variáveis medidas em unidades diferentes. Essas análises estatísticas são classificadas como técnicas de interdependência, nas quais nenhuma variável é definida como independente ou dependente, pois o processo envolve a análise simultânea de todas as variáveis presentes no conjunto de dados.

Dada uma matriz de dados com p atributos (variáveis disponíveis no conjunto de dados), sendo $j = 1, 2, \dots, p$ e a mesma com n objetos (pontos amostrais) de tal forma que $i = 1, 2, \dots, n$, seguindo essas considerações temos o processo de padronização:

$$Z_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j} \quad (4)$$

em que X_{ij} é o valor da i – ésima amostra e j – ésima variável, Z_{ij} portanto é o valor padronizado na matriz de dados, $\bar{X}_j$ é média aritmética da variável j e S_j é o seu desvio padrão.

A análise de agrupamentos hierárquico (*Hierarchical Cluster Analysis*) foi conduzida a partir de uma matriz de similaridade entre os municípios a partir das suas diversas variáveis, de modo que os pontos amostrais dos estados (municípios) foram classificados em três grupos diferentes. Os municípios dentro de um mesmo grupo indicam que estes são homogêneos (os mais semelhantes) entre si, e heterogêneos entre os outros (as mais dissemelhantes). O processo de analisar indivíduos e observar a similaridade entre eles, foi dado por um coeficiente de semelhança. Neste trabalho utilizou-se a distância Euclidiana como medida de dissimilaridade, pois é a medição que apresenta os quão diferentes ou distantes estão dois objetos dentro do espaço n -dimensional. Portanto, os dados para uma análise de agrupamentos consistiram dos valores de p variáveis $X_1, X_2, \dots, X_p$ para n pontos amostrais:

$$d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2}, \quad (5)$$

em que d_{ij} é a distância euclidiana entre os municípios i e j , x_{ik} é o valor da variável X_k para o município i e x_{jk} é o valor da mesma variável X_k para o município j .

Após os cálculos, construiu-se a matriz de distâncias entre os municípios. Essa matriz utiliza os coeficientes de dissimilaridade para identificar a

proximidade entre os municípios. O método de agrupamento hierárquico consistiu em calcular as distâncias entre os municípios para agrupá-los de maneira que, gradualmente, os objetos se associem, até que todos pertençam a um único grupo (Hair *et al.*, 2005). O método de agregação hierárquica de Ward, também conhecido como método de variância mínima, foi utilizado como método de agregação. Esse método minimiza a soma dos quadrados das diferenças dentro dos grupos, calculada em todas as variáveis (Hair *et al.*, 2005). A cada etapa do procedimento de agrupamento, a soma interna dos quadrados é minimizada para todas as possíveis combinações de dois grupos formados no estágio anterior. O método de Ward é especialmente recomendado para dados de origem biológica devido à sua capacidade de formar grupos homogêneos e bem definidos.

A análise de componentes principais (ACP) é uma técnica que transforma grandes quantidades de variáveis, e às reescreve em um conjunto de variáveis menor não correlacionados e com mínima perda de possíveis informações das variáveis iniciais (os chamados componentes principais – CPs), ou seja, as ACP são novas variáveis não correlacionadas entre si, criadas a partir das variáveis originais que apresentam certa semelhança/correlação. Essas CPs são combinações lineares das variáveis originais que criam eixos ortogonais onde são distribuídos em gráficos bidimensionais (*bipLOTS*). A análise maximiza a variância, mostrando o poder discriminatório de cada variável, sendo as primeiras componentes mais providas de informação e os últimos componentes com menos informação.

As seguintes equações são combinações lineares das variáveis originais:

$$\begin{aligned} CP1 &= a_{11}X_1 + a_{21}X_2 + \dots + a_{p1}X_p, \\ CP2 &= a_{12}X_1 + a_{22}X_2 + \dots + a_{p2}X_p, \\ &\vdots \\ CPn &= a_{1n}X_1 + a_{2n}X_2 + \dots + a_{pn}X_p \end{aligned} \quad (6)$$

Neste trabalho, o critério utilizado para selecionar as componentes principais se deu pela quantidade relevante de informação captada, ou seja, aquelas que apresentarem autovalor maior ou igual a 1 (Kaiser, 1958). A partir das componentes encontradas construíram-se gráficos mostrando a nova distribuição das unidades.

A Figura 2 resume o processo metodológico, apresentando o fluxograma da metodologia de tratamento dos dados adotada para o desenvolvimento deste trabalho.




Figura 2. Fluxograma da metodologia de tratamento dos dados.

4 RESULTADOS E DISCUSSÕES

4.1 Estatística Descritiva

A Tabela 3 foi obtida a partir da concentração média de CO_2 (XCO_2) e CH_4 (XCH_4) atmosférico, das observações dos municípios de cada estado, e apresenta a estatística descritiva para XCO_2 e XCH_4 para o período de 2015 a 2023 com intervalo a cada 4 anos. Foram observados valores crescentes de mínimos, médios, máximos e das medianas ao longo da série temporal, corroborando-se à tendência histórica de aumento das concentrações médias desses gases na atmosfera (Hakkarainen *et al.*, 2016). Para a Fluorescência da Clorofila Induzida pelo Sol (SIF), os valores não apresentaram aumentos ou diminuição significativos ao longo dos anos estudados.

Os resultados indicam que para o estado de Goiás (GO), foi observado um aumento de 4,53 e 3,63% para XCO_2 e XCH_4 , respectivamente; enquanto para Mato Grosso do Sul (MS), esses valores foram de 4,52 e 3%; e o maior acréscimo para o Mato Grosso (MT) de 4,63 e 3,76%. Em relação à variabilidade total dos dados observados, considerando-se todos os anos do período, o XCO_2 apresentou CV máximo de até 28%, enquanto o XCH_4 , de 30% e, a SIF apresentou os maiores valores de variabilidade, sendo esses de até 42% (valores não apresentados). Para XCO_2 e XCH_4 , os valores médios de CV foi cerca de 20%. Tais resultados indicam que os dados de XCO_2 e XCH_4 apresentaram menor variabilidade, comparado à SIF, podendo ser considerados mais homogêneos e, conseqüentemente, aptos para um processo de modelagem capaz de gerar estimativas mais confiáveis e robustas. Essa maior robustez decorre do elevado número de observações disponíveis para essas

variáveis no conjunto proveniente do satélite, especialmente para XCO_2 , que apresentou a maior quantidade de registros, superior a 50000 para todos os anos do período analisado, enquanto para XCH_4 e SIF, cerca de 4000 e 3000, respectivamente. Outro indicativo da variabilidade dos dados é a distância entre a média e a mediana, juntamente com os coeficientes de forma, assimetria e curtose. Esses valores indicam o quão próximas as distribuições dos dados estão de uma distribuição normal, esperada para esse tipo de fenômeno. Quanto menor essa diferença e quanto mais próximos de zero esses coeficientes, mais próxima de uma distribuição normal tendem a estar os dados. Diante do exposto, os resultados indicam que XCO_2 e XCH_4 apresentaram distribuição próxima à distribuição normal (Tabela 3 – visualização simplificada da série temporal a cada 4 anos) e SIF (dados não apresentados).

Tabela 3. Estatística descritiva para XCO₂ e XCH₄ entre os estados, no período de 2015 a 2023.

ano	estado	N	média	mediana	variância	desvio padrão	CV	assimetria	curtose
----- XCO ₂ (ppm) -----									
2015	GO	238	399,21	399,09	1,26	1,12	0,28	0,40	2,31
2019	GO	229	409,04	408,93	1,05	1,02	0,25	1,33	4,31
2023	GO	248	418,16	418,03	0,76	0,87	0,21	1,43	4,76
2015	MS	75	398,52	398,57	0,47	0,69	0,17	-1,00	6,40
2019	MS	78	408,83	408,85	0,73	0,86	0,21	0,62	1,31
2023	MS	79	417,39	417,36	0,60	0,77	0,19	0,21	0,34
2015	MT	141	398,96	398,94	0,30	0,55	0,14	0,22	3,64
2019	MT	140	409,53	409,46	0,81	0,90	0,22	1,26	3,07
2023	MT	139	418,33	418,25	0,77	0,87	0,21	1,00	3,02
----- XCH ₄ (ppb) -----									
2015	GO	238	1808,2	1808,1	7,90	2,81	0,16	-0,12	0,13
2019	GO	229	1842,8	1843,3	7,48	2,74	0,15	0,11	-0,40
2023	GO	255	1890,9	1891,4	10,91	3,30	0,17	-0,89	3,80
2015	MS	75	1812,7	1811,9	14,41	3,80	0,21	0,30	0,39
2019	MS	78	1840,0	1838,5	25,26	5,03	0,27	0,52	-0,98
2023	MS	83	1882,6	1881,8	29,17	5,40	0,29	0,54	0,68
2015	MT	141	1814,7	1813,9	18,70	4,32	0,24	1,22	4,76
2019	MT	140	1850,8	1850,4	14,21	3,77	0,20	0,30	-0,43
2023	MT	143	1897,4	1896,5	14,87	3,86	0,20	0,49	2,91

*N – número de observações; CV – Coeficiente de Variação.

4.2 Análise da variabilidade espacial

A Tabela 4 e a Figura 3 apresentam os modelos ajustados aos semivariogramas experimentais para XCO₂, XCH₄ e SIF, para o ano de 2021, usado como referência. Os modelos Exponenciais foram aqueles que melhor se ajustaram aos semivariogramas experimentais para estas variáveis. Para XCH₄ não foi observada dependência espacial para os estados avaliados, ou seja, os modelos apresentaram variabilidade espacial pouco explicada, podendo ser decorrente da menor quantidade de observações ou devido à menor resolução espacial dos sinais de XCH₄ provenientes dos sensores orbitais. Assim, o semivariograma pode ter sido estimado com poucos pontos, tornando o

processo de ajuste do modelo matemático teórico pouco confiável, ocorrendo o fenômeno com capacidade infinita de dispersão, modelos cuja variância não atinge um patamar máximo, ou seja, continua a aumentar com a distância, não sendo possível definir a covariância (Vieira et al., 2000). O coeficiente de determinação (R^2) quantifica a proporção da variabilidade explicada por um modelo no processo de ajuste ao semivariograma experimental. Os melhores valores de R^2 entre as variáveis analisadas foram de 0,97 para XCO_2 , 0,76 para XCH_4 e 0,91 para SIF, sendo superiores a 0,95 para as variáveis do NASA POWER. O alcance (a) é a distância na qual as observações são autocorrelacionadas, ou seja, é a distância da dependência espacial, quanto maior esse valor, maior é a dependência espacial entre as amostras. Os maiores valores de alcance na região foram observados para XCH_4 . No entanto esse comportamento está associado, principalmente, à menor resolução espacial do sensor (10×10 km). Resoluções amplas promovem um efeito de suavização espacial, no qual cada valor representa a média de uma grande área, reduzindo a variabilidade local e resultando em superfícies mais homogêneas, gerando maior continuidade espacial. Assim, o grande valor de alcance observado pode não refletir o padrão de variabilidade espacial do metano atmosférico. Enquanto isso, para XCO_2 e SIF a estrutura de variabilidade apresentou-se mais homogênea, todos os estados avaliados apresentaram valores de alcance de cerca de 40 km. Portanto, foram observados valores menores e mais próximos de alcance para o XCO_2 e SIF, indicando menor autocorrelação espacial quando comparados ao XCH_4 . Tais resultados refletem uma condição mais fiel das variações locais, dada a maior sensibilidade desses produtos a condições

ambientais de menor escala. Assim, para todos as variáveis foi feita a modelagem geoestatística dos municípios individualmente, para cada ano de estudo.

Tabela 4. Modelos e parâmetros dos modelos ajustados aos semivariogramas experimentais para concentração de CO₂ atmosféricos, concentração de CH₄ atmosférico e SIF, para o Brasil Central no ano de 2021 (valores aproximados).

Ano	Modelo	C ₀	C ₀ +C ₁	a	GDE	SQR	R ²
----- XCO ₂ -----							
2020	Exp	1,40	2,48	0,51	0,78	7395	0,97
----- XCH ₄ -----							
2020	Exp	200,78	15519	1803,28	0,01	8,13×10 ⁹	0,76
----- SIF -----							
2020	Exp	0,04	0,04	0,55	0,78	0,68	0,91

Exp: Exponencial; C₀: efeito pepita; C₀ + C₁: patamar; a: alcance (em graus, onde 1 grau equivale a aproximadamente 111,32 km); GDE: grau de dependência espacial; SQR: Soma dos Quadrados dos Resíduos e R²: coeficiente de determinação do ajuste do modelo.




Figura 3. Modelos dos semivariogramas experimentais para as variáveis XCO₂, XCH₄ e SIF para o Brasil Central no ano de 2021, com os parâmetros dos modelos ajustados aos semivariogramas (C₀, C₀+C₁, “a” e R²).

4.3 Análise de correlação linear

A Figura 4 apresenta a matriz de correlação espaço-temporal obtida a partir da base completa dos dados, no período de 2015 a 2023. Essa matriz foi gerada pelo método de correlação linear de Pearson e estimada de forma pareada, permitindo que cada coeficiente fosse calculado com base usando as observações em pares em todas as variáveis. Isso permite aproveitar a maior parte dos dados disponíveis e reduzir a perda de informação. A análise da Figura 4 permitiu verificar de forma geral as principais variáveis influentes sobre os mapas de padrões espaciais de XCO_2 e XCH_4 , assim como as diferentes intensidades entre os graus de associação destas. Assim, observou-se que variáveis como desmatamento e queimadas, Índice de Área Foliar (LAI), Radiação Fotossinteticamente Ativa (FPAR), pressão atmosférica e a temperatura exibiram as correlações positivas mais intensas com a anomalia de XCH_4 , com valores de coeficiente de correlação (r) superiores a 0,22. Tal resultado sugere que esses elementos ambientais e antrópicos exercem papel mais relevante na explicação da variabilidade de XCH_4 observada na série. Enquanto isso, a variável XCO_2 teve como maior correlação, e positiva, associada à anomalia de XCH_4 . Isso reforça que a distribuição espacial do XCH_4 expressa forte correlação entre o XCH_4 e a anomalia XCO_2 (de Souza Maria *et al.*, 2023). Para essa última variável não houve demais correlações significativas.

De maneira geral, tais resultados indicaram maiores intensidades da correlação entre as anomalias de XCO_2 e XCH_4 , e desta última com as variáveis desmatamento, queimada, vento, radiação e LAI. A variável XCO_2 destacou-se quanto à força da correlação (positiva) com as queimadas, no ano de 2018 ($r =$

0,17, valor não apresentado), porém de modo contrário, apresentou maior intensidade de correlação (negativa) com as queimadas no ano de 2016 ($r = -0,22$). O XCH_4 apresentou as maiores correlações positivas com as variáveis queimada ($r = 0,32$), desmatamento ($r = 0,34$), LAI ($r = 0,37$) e FPAR ($r = 0,32$), considerando toda a série temporal analisada (valores entre parênteses referem-se ao ano de 2020). Em contrapartida, as correlações negativas mais expressivas foram observadas para as variáveis velocidade do vento (máximo observado $r = -0,53$) e radiação solar (máximo observado $r = -0,58$). Essas correlações podem indicar que atividades antrópicas relacionadas à degradação e à supressão da vegetação nativa exercem forte influência sobre o aumento das concentrações de metano atmosférico. Além disso, variáveis de origem natural, como vento e radiação, podem atenuar ou mascarar esses padrões, dificultando a identificação direta dos efeitos antrópicos.

Deve-se destacar que a base de dados do DETER, utilizada como fonte dos dados de focos de queimadas, foi pouca representativa por não conter dados para todos os biomas dos estados em estudo, tão pouco durante toda a série temporal analisada. Isso tornou os mapas de correlação menos representativos, apresentando lacunas interpretativas às demais áreas. Sendo assim, estes dados foram e devem ser considerados com devida parcimônia durante as análises. Portanto, sugere-se a adição de novas bases de dados que contenham informações sobre estes focos em análises futuras, como os mapas do MapBiomas, que embora possam apresentar menor precisão, supririam tais lacunas (Souza *et al.*, 2020; MapBiomas, 2021; Guarenghi *et al.*, 2023).




Figura 4. Matriz de coeficientes de correlação linear de Pearson para os dados gerais independente do ano na série temporal.

4.4 Padrões espaciais de XCO₂, XCH₄ e anomalias

Foram gerados os mapas de XCO₂ e XCH₄ e suas respectivas anomalias para toda a série temporal (por exemplo, Figura 5A a 14A). Esses mapas permitem verificar os municípios de maior emissão comparativamente aos níveis de fundo, identificando padrões específicos de emissão, de modo a auxiliar na diferenciação entre as fontes de emissão naturais e antrópicas. De maneira geral, observou-se as maiores emissões de XCO₂ para o estado de Goiás (GO), enquanto as maiores emissões para XCH₄ foram observadas para os estados Mato Grosso (MT) e Mato Grosso do Sul (MS), provavelmente pelas diferenças nas atividades agropecuárias.

As anomalias de XCO_2 e XCH_4 acompanharam semelhante evolução no decorrer dos anos analisados. A faixa de valores para a anomalia de XCO_2 situou-se entre -2,5 e 6 ppm, enquanto a de XCH_4 entre -20 e 30 ppb. Esses resultados indicam, além das fontes líquidas de emissão, importantes áreas de sumidouros de metano, identificadas na região Sul do Mato Grosso do Sul (MS), coincidindo com região de latossolos, frequentemente presente em terras altas, além de região com predomínio de florestas tropicais como a Mata Atlântica. Tal constatação encontra embasamento ao trabalho de Li et al. (2025), ao demonstrarem que solos de terras altas (frequentemente associados a latossolos) representam importantes sumidouros terrestres de metano, removendo CH_4 da atmosfera via oxidação microbiana. Assim como ao trabalho de Arnold et al. (2025), que identificou a capacidade da microbiota presente nos troncos das árvores em consumir CH_4 em florestas tropicais. Ademais, é possível notar que ao longo da série temporal, ambas as anomalias apresentaram dispersão pelos municípios, ou seja, determinados municípios com menores anomalias no início da série temporal tiveram acréscimo gradativo ao longo do tempo. Além disso, quando associados aos mapas de agrupamento (p.ex. Figura 5B) e *biplots* (p.ex. Figura 5C), possibilitam verificar visualmente as correlações entre as variações nos níveis das emissões de CO_2 e CH_4 e as variáveis de maior influência responsáveis pela classificação nos determinados grupos.

Ademais, em todos os anos observou-se o vento como uma das principais variáveis para determinação dos padrões espaciais de emissão, como o da Figura 5B, correlacionando-se negativamente com as anomalias. Esse padrão é muito semelhante ao mapa da velocidade média do vento da região, o que se

esperado, pois demonstra o vento como um mascarador das emissões locais (GWA, 2026).

Ainda que mantida a forte correlação com o vento em todos os anos, a formação dos grupos se alterou de forma parecida, ou seja, ora apresentou o padrão da Figura 5B, ora o padrão da figura 7B. Porém, no ano de 2020, o município de Corumbá, destacado com um ponto vermelho (Figura 10B) alterou este comportamento: em que seu passou a ser ditado principalmente pela anomalia de XCH_4 correlacionada ao desmatamento, e uma nova forte correlação na CP3 entre a anomalia de XCO_2 e XCH_4 foi destacada, sendo a maior entre todos os anos analisados.

O ano de 2020 registrou recorde no número de focos de incêndio no pantanal, principal bioma desse município. Historicamente, os incêndios no pantanal ocorrem na época mais seca do ano e da região, em setembro, antes do período de chuva. Dessa forma, as queimadas possivelmente favoreceram a mais forte correlação da anomalia de XCO_2 com a de XCH_4 . Além disso, as emissões provenientes do setor de MUT, que contabilizam os desmatamentos, foram extremamente elevadas ($3,23 \times 10^6$ toneladas de CO_2 equivalente de 100 anos - MT CO_2 eq) e a do setor Agropecuário ($6,80 \times 10^6$ toneladas CO_2 eq) foi superior aos outros anos de estudo. Nos anos seguintes, observamos que Corumbá passou a ser classificado no grupo 3, assim como outros municípios próximos alteraram seu padrão de comportamento. Possivelmente porque o pico das queimadas ocorreram próximo ao final de 2020, junto com intensos desmatamentos, e as emissões associadas ao desmatamento fez com que fosse determinante sua classificação no grupo 2. Além disso, o fogo libera CO_2

imediatamente, mas também pode aumentar condições favoráveis à emissão de CH_4 em seguida. O Pantanal por ser uma região úmida, faz com que parte da combustão ocorra de forma incompleta, e o processo de liberação de CH_4 seja dado gradualmente pela decomposição anaeróbica da matéria orgânica. Ou seja, as emissões seguintes de CH_4 , muito provavelmente foram resultantes das queimadas, apesar de correlacionadas negativamente ao desmatamento no ano de 2021, se prolongaram ao longo do tempo, se relacionando com as emissões de XCO_2 .

4.5 Análise das componentes principais (ACP)

O Poder discriminante corresponde à correlação entre as cargas fatoriais (*loadings*) e as variáveis originais, destacando quais variáveis mais contribuíram para a formação de cada componente principal. São apresentadas as tabelas das componentes principais (CP) para cada ano da série temporal (Tabela 5 à Tabela 13). Cada tabela demonstra os coeficientes de correlação entre as variáveis e cada um dos componentes principais (CP1-CP3). Os autovalores (*eigenvalues*) indicam a quantidade de variância total dos dados explicada por cada componente principal. Componentes com autovalores mais altos são mais relevantes para interpretação. Desse modo, reitera-se que somente foram considerados os autovalores maiores que 1 (10%) para análise. A Porcentagem da variância explicada, também apresentada nessas tabelas, permitem verificar a proporção da variância total dos dados explicada individualmente por cada componente principal. Enquanto a porcentagem da variância explicada acumulada (valores não dispostos de forma explícita), que seria dada pela soma da variância explicada, representa o total de variância explicada pela soma dos

primeiros componentes. Entre os anos da série temporal, essa porcentagem acumulada ficou entre 66 e 75% quando considerados os componentes com autovalores maiores que 1 sendo, nesses casos, geralmente os três primeiros componentes principais.

Em seguida são apresentados os mapas gerados a partir dos dendrogramas resultantes do processo de agrupamento (Figura 5B à 13B). O número ótimo de grupos foi determinado a partir do ponto de corte correspondente ao maior incremento observado na distância euclidiana entre os níveis de junção observados nos dendrogramas (resultados não apresentados). Também são apresentados os gráficos bidimensionais (*biplots* – Figura 5C à 13C). Com relação aos mapas, é possível notar que os municípios da região do Brasil central foram classificados em três grupos principais. Ademais, relacionado aos *biplots*, observa-se determinado padrão de flutuação entre as principais variáveis influentes nos valores de emissão. Essas variações foram comentadas anualmente, assim como os municípios do grupo 3, que apresentaram comportamento contrastante ao padrão dos demais grupos. Ressalta-se que a ausência de dados integrais das queimadas ao longo de todos os anos e biomas analisados, especificamente Pantanal e Cerrado, dificultaram a interpretação. Por exemplo para o grupo 3, especificamente na região do bioma do Pantanal (p.ex. para o município de Corumbá, destacado com um ponto vermelho nas figuras 10B e 11B): este passou por diversos incêndios no período, tendo seu pico no ano de 2020 (Câmara; Lélis, 2023; Câmara, 2022; INPE, 2026), associado aos períodos de seca (pico em setembro), o que pode justificar

sua correlação com as demais variáveis do grupo 2, e, portanto, a mudança de grupo atípica neste mesmo ano (Figuras 10B e 11B).

4.6 Ano 2015

Para o ano de 2015, as três primeiras componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 45%, 19% e 12% da variabilidade total, respectivamente, totalizando 76%. CP1 foi negativamente correlacionada com variáveis climáticas e vegetativas, destacando-se a pressão atmosférica e a umidade do ar (-0,95). CP2 representa um contraste entre anomalia de XCH_4 (0,71) e Desmatamento (0,50) contra a velocidade do vento (-0,74). Por sua vez o CP3 representou a anomalia de XCO_2 (alto poder discriminante) para qual não foi observado demais valores correlacionados.

A análise de agrupamento (Figura 5B) aliada à interpretação do gráfico *biplot* (Figura 5C) indicam o agrupamento dos municípios localizados, principalmente ao norte da área estudada, na sua maioria pertencentes ao estado do MT. Tais municípios, podem ser caracterizados, especialmente pelos maiores valores de desmatamento e Anomalia de XCH_4 (grupo 1). O grupo 2 foi formado pelos demais municípios pertencentes ao Brasil central, caracterizados por menores índices de desmatamento e Anomalia de XCH_4 , relativamente, com maiores influências das variáveis climáticas e vegetativas. Além disso, deve-se destacar os municípios que apresentaram os menores valores dessas variáveis (grupo 3), o que podem ser considerados *outliers* (Adelândia; Anhanguera; Aparecida do Rio Doce; Avelinópolis; Buriti de Goiás; Cumari; Estrela do Norte; Nova Aurora; Palminópolis; Pires do Rio; Santa Rita do Araguaia; Eldorado;

Japorã; Vicentina; Araguainha; Jangada; Mirassol D'oeste; Nortelândia; Rio Branco).

Tabela 5. Autovalores, variância explicada e valores de coeficientes de correlação entre cada variável analisada e a respectiva componente principal (CP1 a CP3), para o ano de 2015.

Componente Principal	CP1	CP2	CP3
Autovalores	4,47	1,86	1,16
Variância explicada (%)	45	19	12
Correlações			
Anomalia de XCO ₂	0,02	-0,19	-0,85
Anomalia de XCH ₄	-0,14	0,71	0,27
Desmatamento	-0,17	0,50	-0,31
Vento	-0,35	-0,74	-0,03
Precipitação	-0,80	-0,09	0,29
LAI	-0,60	0,56	-0,28
FPAR	-0,82	0,29	-0,17
Radiação	-0,90	-0,27	-0,09
Umidade	-0,95	-0,08	0,15
Pressão	-0,95	-0,12	0,03
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento	
			Anomalia de XCO ₂

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,50$ em módulo).




Figura 5. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO₂ e XCH₄ e suas respectivas anomalias (A), para o ano de 2015. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2015 (C).

4.7 Ano 2016

Para o ano de 2016, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 40%, 21% e 10% da variabilidade total, respectivamente, totalizando 71%. CP1 foi negativamente correlacionada com variáveis climáticas e vegetativas, destacando-se assim como para 2015, a pressão atmosférica e a umidade do ar ($\sim -0,95$). E de modo semelhante, a CP2 representou um contraste entre anomalia de XCH_4 (0,80) e desmatamento (0,44) contra a velocidade do vento ($-0,72$). Por sua vez a CP3 representou a anomalia de XCO_2 com alto poder discriminante (0,85), sendo quase exclusivamente definida por ela. A análise de agrupamento (Figura 6B) aliada à interpretação do gráfico *biplot* (Figura 6C) indicam o agrupamento dos municípios localizados, principalmente ao norte da área estudada, na sua maioria pertencentes ao estado do MT. Tais municípios, podem ser caracterizados, especialmente pelos maiores valores de desmatamento e anomalia de XCH_4 (grupo 1). O grupo 2 foi formado de modo semelhante ao ano anterior. Porém, os municípios que apresentaram os menores valores dessas variáveis, de maneira a constituir o grupo 3, foram Adelândia; Águas Lindas de Goiás; Anhanguera; Aparecida do Rio Doce; Aracu; Buriti de Goiás; Cumari; Estrela do Norte; Nova Aurora; Ouvidor; Palminópolis; Pires do Rio; Santa Rita do Araguaia; Araguainha; Jangada; Nortelândia; Rio Branco.

Tabela 6. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2016.

Componente Principal	CP1	CP2	CP3
Autovalores	4,39	2,27	1,12
Variância explicada (%)	40	21	10
Correlações			
Anomalia de XCO ₂	-0,07	0,34	0,85
Anomalia de XCH ₄	-0,16	0,80	0,02
Desmatamento	-0,16	0,44	-0,19
Vento	-0,23	-0,72	0,44
Precipitação	-0,83	0,00	-0,25
LAI	-0,62	0,57	0,06
FPAR	-0,81	0,31	0,17
Radiação	-0,89	-0,33	0,11
Umidade	-0,92	-0,18	-0,19
Pressão	-0,94	-0,21	-0,02
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento	Anomalia de XCO ₂

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,44$ em módulo).




Figura 6. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO₂ e XCH₄ e suas respectivas anomalias (A), para o ano de 2016. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2016 (C).

4.8 Ano 2017

Para o ano de 2017, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 43%, 20% e 10% da variabilidade total, respectivamente, totalizando 73%. CP1 foi positivamente correlacionada com variáveis climáticas e vegetativas, destacando-se assim como para os anos anteriores, a pressão atmosférica e a umidade do ar (0,95). De modo semelhante, a CP2 representou um contraste entre Anomalia de XCH_4 (0,78) e Desmatamento (0,54) contra a velocidade do vento (-0,76). Essa diferença em relação ao ano anterior indicam um aumento da influência do desmatamento na categorização dos estados do MT e MS em mesmo grupo neste ano. A CP3 representou a anomalia de XCO_2 de modo semelhante. A análise de agrupamento (Figura 7B) aliada à interpretação do gráfico *biplot* (Figura 7C) indicam o agrupamento dos municípios localizados para este ano, ao norte e oeste da área estudada, sendo em quase toda a extensão pertencente ao estado do MT, e boa parte do MS. Tais municípios, podem ser caracterizados, especialmente pelos maiores valores de desmatamento e anomalia de XCH_4 (grupo 1). O grupo 2 foi formado de modo semelhante aos anos anteriores. Porém, os municípios que apresentaram os menores valores dessas variáveis, de maneira a constituir o grupo 3, foram Adelândia; Americano do Brasil; Anhanguera; Aparecida do Rio Doce; Aracu; Avelinópolis; Campestre de Goiás; Cumari; Estrela do Norte; Guaraita; Lagoa Santa; Morro Agudo de Goiás; Nova Aurora; Novo Gama; Palminópolis; Pires do Rio; Santa Rita do Araguaia; Valparaíso de Goiás; Eldorado; Juti; Vicentina; Araguainha; Jangada; Mirassol D'oeste; Rio Branco; São Pedro da Cipa.

Tabela 7. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2017.

Componente Principal	CP1	CP2	CP3
Autovalores	4,75	2,17	1,07
Variância explicada (%)	43	20	10
Correlações			
Anomalia de XCO ₂	-0,02	0,00	-0,95
Anomalia de XCH ₄	0,02	0,78	-0,15
Desmatamento	0,17	0,54	-0,14
Vento	0,35	-0,76	-0,24
Precipitação	0,84	0,05	0,21
LAI	0,67	0,50	-0,05
FPAR	0,87	0,20	-0,04
Radiação	0,91	-0,26	-0,11
Umidade	0,95	-0,03	0,12
Pressão	0,95	-0,13	-0,03
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento	Anomalia de XCO ₂

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,54$ em módulo).




Figura 7. Mapas de padrões espaciais gerados a partir da krigagem ordinárias para XCO₂ e XCH₄ e suas respectivas anomalias (A), para o ano de 2017. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2017 (C).

4.9 Ano 2018

Para o ano de 2018, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 45%, 18% e 9% da variabilidade total, respectivamente, totalizando 72%. CP1 foi negativamente correlacionada com variáveis climáticas e vegetativas, destacando-se assim como para os anos anteriores, a pressão atmosférica e a umidade do ar ($\sim 0,95$). De modo semelhante, a CP2 representou um contraste entre anomalia de XCH_4 (0,60) e Desmatamento (0,61) contra a velocidade do vento (-0,76). A CP3 representou a anomalia de XCO_2 de modo análogo aos anos anteriores. A análise da Figura 8B associada à interpretação do *biplot* (Figura 8C) demonstraram comportamento semelhante ao ano 2015 e 2016, indicando o agrupamento dos municípios localizados ao norte do MT, caracterizando-os, também, pelos maiores valores de desmatamento e anomalia de XCH_4 (grupo 1). O grupo 2 foi formado de modo semelhante ao ano anterior, porém dessa vez diferenciou-se pela ligeira menor influência da anomalia XCH_4 . Assim, corroborando-se às emissões evidenciadas pelo Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG, 2018; SEEG, 2024), o setor de maior emissão para a região do grupo 1 tem como principal influência o setor de Mudança de uso da terra e florestas (MUT). Enquanto as emissões do grupo 2, grande influência do setor agropecuário. Os municípios que apresentaram os menores valores dessas variáveis (grupo 3), foram Abadia de Goiás; Adelândia; Aguas Lindas de Goiás; Anhanguera; Aparecida do Rio Doce; Aracu; Aragoiania; Avelinópolis; Caturai; Estrela do Norte; Guaraita; Heitorai; Itaguari; Lagoa Santa; Nova Aurora; Novo Gama; Ouvidor; Palminópolis; Pires do Rio; Santa Rita do

Araguaia; São Patricio; Valparaíso de Goiás; Vicentina; Araguainha; Mirassol D'oeste; Rio Branco.

Tabela 8. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2018.

Componente Principal	CP1	CP2	CP3
Autovalores	4,95	1,96	1,03
Variância Explicada (%)	45	18	9
Correlações			
Anomalia de XCO ₂	-0,05	0,21	0,94
Anomalia de XCH ₄	-0,21	0,60	-0,34
Desmatamento	-0,21	0,61	0,04
Vento	-0,33	-0,78	0,05
Precipitação	-0,86	0,15	-0,01
LAI	-0,71	0,40	0,07
FPAR	-0,89	0,11	0,01
Radiação	-0,92	-0,31	0,05
Umidade	-0,96	-0,05	-0,06
Pressão	-0,95	-0,19	-0,04
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento	Anomalia de XCO ₂

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,60$ em módulo).




Figura 8. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO_2 e XCH_4 e suas respectivas anomalias (A), para o ano de 2018. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2018 (C).

4.10 Ano 2019

Para o ano de 2019, foram caracterizados somente dois componentes principais, CP1 e CP2, que explicaram aproximadamente 43% e 20% da variabilidade total, respectivamente, totalizando 63%. A CP1 foi correlacionada de forma negativa com as variáveis climáticas e vegetativas, destacando-se assim como para os anos anteriores, a pressão atmosférica e a umidade do ar ($\sim 0,95$). Por outro lado, a CP2 representou um intenso contraste entre anomalia de XCO_2 (0,76), moderado com Desmatamento (0,61) e menor com a anomalia XCH_4 (0,37); contra a velocidade do vento (-0,76). A análise da Figura 9B associada à interpretação do *biplot* (Figura 9C) demonstrou um comportamento próximo ao ano 2017, no entanto abrangendo quase integralmente toda a região do Brasil Central, caracterizando-os, pelos maiores valores de desmatamento, anomalia de XCO_2 e XCH_4 (grupo 1). O grupo 2 foi formado pelos maiores índices de Anomalia XCO_2 , Desmatamento e Anomalia XCH_4 . Os municípios que apresentaram os menores valores dessas variáveis, de maneira a constituir o grupo 3, foram Adelândia; Anhanguera; Aparecida do Rio Doce; Avelinópolis; Buriti de Goiás; Campestre de Goiás; Caturai; Cristinópolis; Cumari; Estrela do Norte; Firminópolis; Lagoa Santa; Mutunópolis; Nova Aurora; Palminópolis; Pires do Rio; Sanclerlândia; Santa Cruz de Goiás; Valparaíso de Goiás; Jangada; Mirassol D'oeste; Nortelândia; Rio Branco. Os mapas de anomalia para este ano caracterizaram bem os dois primeiros grupos (1 e 2), complementando a verificação das variações incomuns da emissão de GEE (anomalia propriamente dita), permitindo a identificação de *hotspots* (regiões com um aumento

acentuado do GEE) ou *coldspots* (regiões com diminuições pronunciadas do GEE).

Tabela 9. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2019.

Componente Principal	CP1	CP2
Autovalores	4,78	2,25
Variância Explicada (%)	43	20
Correlações		
Anomalia de XCO ₂	-0,07	0,76
Anomalia de XCH ₄	-0,08	0,37
Desmatamento	-0,20	0,61
Vento	-0,35	-0,77
Precipitação	-0,85	0,09
LAI	-0,67	0,46
FPAR	-0,87	0,15
Radiação	-0,92	-0,28
Umidade	-0,96	-0,05
Pressão	-0,95	-0,16
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCO ₂ e XCH ₄ , Desmatamento Versus Velocidade do Vento

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,37$ em módulo).




Figura 9. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO_2 e XCH_4 e suas respectivas anomalias (A), para o ano de 2019. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2019 (C).

4.11 Ano 2020

Para o ano de 2020, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 33%, 21% e 12% da variabilidade total, respectivamente, totalizando 66%. CP1 foi positivamente correlacionada com variáveis climáticas e vegetativas, destacando-se assim como para os anos anteriores, a pressão atmosférica (0,91) e a umidade do ar ($\sim 0,86$). Para esse ano, variáveis como precipitação (0,68) e LAI (0,57), obtiveram menores valores de correlação. Mais uma vez a CP2 representou um contraste entre anomalia de XCH₄ (0,64) e Desmatamento (0,52) contra a velocidade do vento (-0,79). A CP3 representou a anomalia de XCO₂ de modo análogo aos anos anteriores, com considerável correlação à anomalia de XCH₄ (0,59). A análise da Figura 10B associada à interpretação do *biplot* (Figura 10C) demonstraram comportamento semelhante ao ano 2015 e 2016, indicando o agrupamento dos municípios localizados ao norte do MT, caracterizando-os, também, pelos maiores valores de desmatamento e anomalia de XCH₄ (grupo 1). No entanto, neste ano é possível notar que o município de Corumbá (destacado com um ponto vermelho na Figura 10B) foi o único do estado do MS a apresentar comportamento semelhante ao grupo 1. Por meio das análises, observou-se para essa cidade que as emissões provenientes do setor de MUT foram extremamente elevadas ($3,23 \times 10^6$ M toneladas de CO₂ equivalente de 100 anos - MT CO₂ eq) e a do setor Agropecuário ($6,80 \times 10^6$ MT CO₂ eq) foi superior aos outros anos de estudo. O grupo 2 foi formado de modo semelhante à 2019. Os municípios que apresentaram os menores valores dessas variáveis (grupo 3), foram Anhanguera; Aragoiania; Cumari; Nova Aurora; Rio Branco.

Tabela 10. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2020.

Componente Principal	CP1	CP2	CP3
Autovalores	3,59	2,34	1,35
Variância Explicada (%)	33	21	12
Correlações			
Anomalia de XCO ₂	0,04	0,18	0,77
Anomalia de XCH ₄	0,09	0,64	0,59
Desmatamento	0,11	0,52	-0,07
Vento	0,06	-0,79	0,01
Precipitação	0,68	-0,10	0,17
LAI	0,57	0,61	-0,38
FPAR	0,70	0,34	-0,42
Radiação	0,84	-0,41	0,13
Umidade	0,91	-0,12	0,14
Pressão	0,86	-0,17	0,09
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento e LAI	Anomalia de XCO ₂ e XCH ₄

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,52$ em módulo).




Figura 10. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO₂ e XCH₄ e suas respectivas anomalias (A), para o ano de 2020. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2020 (C).

4.12 Ano 2021

Para o ano de 2021, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 42%, 17% e 13% da variabilidade total, respectivamente, totalizando 72%. CP1 foi correlacionada de forma positiva com variáveis climáticas e vegetativas, destacando-se assim como para os anos anteriores, a pressão atmosférica (0,92) e a umidade do ar (0,94). Por outro lado, neste ano a CP2 representou um determinado maior contraste entre anomalia de XCO_2 (-0,62) e anomalia de XCH_4 (-0,64) contra a velocidade do vento (0,72). A CP3 novamente representou a anomalia de XCO_2 , porém de modo inverso ao Desmatamento (-0,43). A análise da Figura 11B associada à interpretação do *biplot* (Figura 11C) demonstraram comportamento um pouco diferente, indicando mais uma vez o agrupamento dos municípios localizados ao norte do MT, caracterizando-os pelos maiores valores de anomalia de XCO_2 , porém agora com maiores valores de Desmatamento e anomalia de XCH_4 (grupo 1). O grupo 2 foi formado de modo similar a anos anteriores, porém com inferior correlação da Anomalia XCO_2 (0,61) e ainda, com certa correlação da anomalia de XCH_4 (0,48). Também é possível visualizar novos municípios apresentando comportamento diferente dos padrões observados até agora (para o grupo 3), assim como Corumbá (destacado com um ponto vermelho na Figura). Esses municípios apresentaram os menores valores para as demais variáveis, porém de modo atípico, demonstrou um contraste entre a anomalia de XCO_2 (0,61) com o Desmatamento (-0,43). São eles: Amambai; Planaltina; Amambai; Bela Vista; Corumbá; Damolândia; Dourados; Jardim; Santa Rita Do Araguaia; Santa

Terezinha; Valparaíso De Goiás; Na; Água Boa; Jussara; Rio Verde; Vera; Vicentina; Jardim.

Tabela 11. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2021.

Componente Principal	CP1	CP2	CP3
Autovalores	4,64	1,91	1,43
Variância Explicada (%)	42	17	13
Correlações			
Anomalia de XCO ₂	0,15	-0,62	0,61
Anomalia de XCH ₄	0,44	-0,60	0,48
Desmatamento	0,16	-0,34	-0,43
Vento	0,22	0,72	0,44
Precipitação	0,80	-0,25	-0,02
LAI	0,67	-0,27	-0,46
FPAR	0,82	0,04	-0,31
Radiação	0,89	0,36	0,18
Umidade	0,94	0,05	0,00
Pressão	0,92	0,26	0,10
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCO ₂ e XCH ₄ Versus Velocidade do Vento	Anomalia de XCO ₂ e XCH ₄ Versus Desmatamento

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,43$ em módulo).




Figura 11. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO_2 e XCH_4 e suas respectivas anomalias (A), para o ano de 2021. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2021 (C).

4.13 Ano 2022

Para o ano de 2022, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 42%, 19% e 11% da variabilidade total, respectivamente, totalizando 72%. CP1 foi correlacionada de forma positiva com variáveis climáticas e vegetativas, destacando-se a pressão atmosférica (0,95) e a umidade do ar (0,96). Mais uma vez a CP2 representou um contraste entre anomalia de XCH_4 (-0,62) e Desmatamento (-0,54) contra a velocidade do vento (0,77). A CP3 apresentou a anomalia de XCO_2 de modo similar ao ano de 2020 e 2021, com considerável correlação à anomalia de XCH_4 (0,53). A análise da Figura 12B associada à interpretação do *biplot* (Figura 12C) demonstraram comportamento semelhante, em que os municípios localizados ao norte do MT foram agrupados pelos maiores valores de Desmatamento e anomalia de XCH_4 (grupo 1). O grupo 2 foi formado com relativa maior correlação da Anomalia XCO_2 (0,88) e Anomalia XCH_4 (0,53), de modo similar a anos anteriores (2020 e 2021). Também é possível visualizar, como no ano anterior, novos municípios apresentando comportamento diferente dos padrões observados até 2020 (para o grupo 3). Esses municípios apresentaram os menores valores para as demais variáveis, sendo eles: Amambai; Planaltina; Amambai; Bela Vista; Corumbá; Dourados; Jardim; Jesupolis; Novo Gama; Santa Terezinha; Na; Agua Boa; Jussara; Rio Verde; Vera; Arenápolis; Jardim; Nortelândia; Rio Branco.

Tabela 12. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2022.

Componente Principal	CP1	CP2	CP3
Autovalores	4,62	2,05	1,22
Variância Explicada (%)	42	19	11
Correlações			
Anomalia de XCO ₂	0,01	-0,08	0,88
Anomalia de XCH ₄	0,15	-0,62	0,53
Desmatamento	0,13	-0,54	-0,17
Vento	0,30	0,77	0,12
Precipitação	0,84	0,07	0,06
LAI	0,63	-0,57	-0,19
FPAR	0,83	-0,25	-0,24
Radiação	0,92	0,27	0,13
Umidade	0,96	0,04	0,00
Pressão	0,95	0,16	0,06
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ e Desmatamento Versus Velocidade do Vento	Anomalia de XCO ₂ e XCH ₄

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,53$ em módulo).




Figura 12. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO₂ e XCH₄ e suas respectivas anomalias (A), para o ano de 2022. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2022 (C).

4.14 Ano 2023

Para o ano de 2023, os componentes principais, CP1, CP2 e CP3, explicaram aproximadamente 45%, 18% e 12% da variabilidade total,

respectivamente, totalizando 75%. CP1 foi correlacionada de forma positiva com variáveis climáticas e vegetativas, destacando-se a pressão atmosférica e a umidade do ar (0,95). Nesse ano a CP2 representou um contraste entre anomalia de XCH₄ (0,68) e Precipitação (0,59) contra a velocidade do vento (-0,76). Isso pode ser devido ausência de dados de desmatamento para todo o ano de 2023, em razão de sua falta durante o período de aquisição dos dados no trabalho. A CP3 apresentou a anomalia de XCO₂ de modo similar ao ano de 2020 a 2022, com considerável correlação à anomalia de XCH₄ (0,41). Por sua vez, a análise da Figura 14B associada à interpretação do *biplot* (Figura 14C) demonstraram comportamento semelhante, em que os municípios localizados ao norte do MT foram agrupados (grupo 1) pelos maiores valores de anomalia de XCH₄ e de XCO₂, e provavelmente apresentariam do Desmatamento, caso presentes para este ano. O grupo 2 foi formado com certa correlação da anomalia XCO₂ (0,74) e Anomalia XCH₄ (0,41), de modo próximo a anos anteriores (2020 a 2022). Também é possível visualizar, como no ano anterior, municípios apresentando comportamento diferente dos padrões observados até 2020 (para o grupo 3). Esses municípios apresentaram os menores valores para as demais variáveis, sendo eles: Amambai; Planaltina; Bela Vista; Corumbá; Dourados; Jardim; Santa Terezinha; Água Boa; Jussara; Rio Verde; Vera; Jangada; Jardim; Nortelândia; Várzea Grande.

Tabela 13. Coeficientes de correlação entre cada variável analisada e o componente principal (CP1 a CP3), apresentando os respectivos autovalores e a quantidade de variância explicada, para o ano de 2023.

Componente Principal	CP1	CP2	CP3
Autovalores	4,50	1,80	1,15
Variância Explicada (%)	45	18	12
Correlações			

Anomalia de XCO ₂	0,01	0,36	0,74
Anomalia de XCH ₄	0,10	0,68	0,41
Vento	0,29	-0,76	0,31
Precipitação	0,62	0,59	-0,34
LAI	0,83	-0,07	-0,17
FPAR	0,85	0,24	-0,24
Radiação	0,89	-0,16	0,30
Umidade	0,95	-0,10	0,00
Pressão	0,95	-0,13	0,17
Interpretação	Variáveis Climáticas e Vegetativas	Anomalia de XCH ₄ Versus Velocidade do Vento	Anomalia de XCO ₂ e XCH ₄

Correlações em negrito foram utilizadas para a interpretação ($\geq 0,41$ em módulo).




Figura 14. Mapas de padrões espaciais gerados a partir da krigagem ordinária para XCO_2 e XCH_4 e suas respectivas anomalias (A), para o ano de 2023. Mapa de agrupamento (B) e *Biplot*, representação bidimensional dos dois primeiros componentes principais para o ano de 2023.

5 CONCLUSÕES

A presença de anomalias negativas de XCH_4 indicam a atuação de sumidouros atmosféricos de metano (CH_4), especialmente concentrados no sul do Mato Grosso do Sul, região coincidente com a predominância de Latossolos e o bioma da Mata Atlântica. Esse padrão evidencia o elevado potencial dessas áreas para a mitigação de gases de efeito estufa. Também foi possível notar as anomalias de XCO_2 e XCH_4 se distribuindo de forma mais ampla entre os municípios ao longo da série temporal, ou seja, localidades que inicialmente apresentavam valores reduzidos de anomalia passaram a registrar aumentos graduais expressivos ao longo dos anos, indicando uma expansão da intensidade dessas anomalias pela região do Brasil Central, reforçando a influência da ação antrópica nas emissões dos GEE.

Além disso, verificou-se que a relação entre as variáveis climáticas e vegetativas permanecem relativamente constantes ao longo do tempo, com pequena variação da precipitação e Índice de Área Foliar (LAI) ao longo da série temporal, como observado para o ano de 2020. As maiores correlações foram observadas entre as anomalias de XCO_2 e XCH_4 , e desta última, com as variáveis desmatamento, queimada, velocidade do vento, radiação solar e LAI. Os valores de correlação obtidos para a anomalia de XCH_4 ($r \geq 0,23$) sugerem que as variáveis vegetativas ($r \sim 0,27$) e climáticas ($r \sim \pm 0,27$), o desmatamento ($r = 0,24$) e as queimadas ($r = 0,28$) exercem papel relevante na explicação da variabilidade de XCH_4 . A anomalia de XCO_2 obteve correlações ainda maiores com a anomalia de XCH_4 a partir do ano de 2020, possivelmente causada pela intensificação simultânea de processos emissores, como o aumento nos

desmatamentos e queimadas, provavelmente associados aos setores de Mudança de uso da terra e florestas (MUT) e Agricultura. Para anos anteriores, a anomalia de XCO_2 obteve correlações fracas entre todas as variáveis estudadas.

Essa abordagem contribuiu para melhorar a compreensão da dinâmica dos gases de efeito estufa na atmosfera e suas interações com variáveis climáticas e vegetativas, associadas aos setores no Brasil Central, de forma a auxiliar na formulação de políticas públicas voltadas para a mitigação das emissões desses gases, frente a necessidade de mitigação às mudanças climáticas.

Por fim, destaca-se o grande potencial para continuidade deste trabalho para identificação exata dos setores e subsetores responsáveis pelas fontes e sumidouros das emissões em cada município.

LITERATURA CITADA

ABIEC. Associação Brasileira das Indústrias Exportadoras de Carne. Beef REPORT: perfil da pecuária no Brasil 2025. Disponível em: <https://www.abiec.com.br/catpub/impressos/>. Acesso em: 20 nov. 2025.

ALMEIDA, C. *et al.* Metodologia utilizada nos sistemas PRODES e DETER. São José dos Campos: INPE, 2022a. Disponível em: <http://mtc-m21d.sid.inpe.br/col/sid.inpe.br/mtc-m21d/2022/08.25>, v. 11, 2022.

ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. Meteorologische zeitschrift, v. 22, n. 6, p. 711-728, 2013.

AppEEARS Team - *Application for Extracting and Exploring Analysis Ready Samples* (AppEEARS). Ver. v3.82. NASA EOSDIS Land Processes Distributed Active Archive Center (LP DAAC), USGS/Earth Resources Observation and Science (EROS) Center, Sioux Falls, South Dakota. 2024. Disponível em: <https://appeears.earthdatacloud.nasa.gov>. Acesso em: 11 dez. 2024.

ARAGÃO, Luiz EOC *et al.* 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature communications**, v. 9, n. 1, p. 536, 2018.

ARNOLD, Wyatt *et al.* A diverse and distinct microbiome inside living trees. **Nature**, v. 644, n. 8078, p. 1039-1048, 2025.

BURROUGH, P. A.; MCDONNELL, R. A. Principles of geographical information system. Oxford: University Press, 1998. 333 p.

CÂMARA, José; LÉLIS, Lucas. Pantanal: fogo já devastou área quase oito vezes maior que o Rio em 2023. G1 Mato Grosso do Sul, Mato Grosso do Sul, 14 nov. 2023. Disponível em: <https://g1.globo.com/ms/mato-grosso-do-sul/noticia/2023/11/14/pantanal-fogo-ja-devastou-area-quase-oito-vezes-maior-que-o-rio-em-2023.ghtml>. Acesso em: 20 maio 2026.

CÂMARA, José. Imagens aéreas mostram incêndio no Pantanal; militares são mobilizados para conter chamas. G1 Mato Grosso do Sul, Mato Grosso do Sul, 27 maio 2022. Disponível em: <https://g1.globo.com/ms/mato-grosso-do-sul/noticia/2022/05/27/imagens-aereas-mostram-incendio-no-pantanal-militares-sao-mobilizados-para-conter-chamas.ghtml>. Acesso em: 20 maio 2026.

CAMARGO, Eduardo Celso Gerbi. Geoestatística: fundamentos e aplicações. Geoprocessamento para projetos ambientais. São José dos Campos: INPE, v. 29, 1998.

CHENG, Shuai *et al.* Observed increase in tropical vegetation droughts over the past three decades. **Geophysical Research Letters**, v. 53, n. 8, p. e2025GL121172, 2026.

CONAB - Companhia Nacional de Abastecimento. 1º Levantamento - Safra 2024/2025. Disponível em: <https://www.gov.br/conab/pt-br>. Acesso em: 12 nov. 2024.

CRESSIE, Noel; GOTWAY, Carol A.; GRONDONA, Martine O. Spatial prediction from networks. *Chemometrics and Intelligent Laboratory Systems*, v. 7, n. 3, p. 251-271, 1990.

CRISP, D. *et al.* The on-orbit performance of the Orbiting Carbon Observatory-2 (OCO 2) instrument and its radiometrically calibrated products. *Atmospheric Measurement Techniques*, v. 10, n. 1, p. 59–81, 2017.

DA COSTA, L. M. *et al.* High spatial resolution solar-induced chlorophyll fluorescence and its relation to rainfall precipitation across Brazilian ecosystems. **Environmental Research**, v. 218, p. 114991, 2023.

DA COSTA, L. M. *et al.* Classificação climática de köppen aplicada em unidades de conservação: estudo de caso no parque estadual do mendanha (pem) e na área de proteção ambiental Gericinó-Mendanha (APAGM). v. 1, p. 1–12, 2021.

DA COSTA, L. M. *et al.* Exploring CO₂ anomalies in Brazilian biomes combining OCO-2 & 3 data: Linkages to wildfires patterns. **Advances in Space Research**, v. 73, n. 8, p. 4158–4174, 2024.

DALCHIAVON, F. C. *et al.* Produtividade da soja e resistência mecânica à penetração do solo sob sistema plantio direto no cerrado brasileiro. *Pesquisa Agropecuária Tropical*, v. 41, n. 1, p. 8–19, jan. 2011.

DE ALMEIDA, Claudio Aparecido *et al.* METODOLOGIA UTILIZADA NOS SISTEMAS PRODES E DETER-2 a EDIÇÃO (ATUALIZADA). **CEP**, v. 12, p. 010, 2022.

DE AZEVEDO, Tasso Rezende *et al.* SEEG initiative estimates of Brazilian greenhouse gas emissions from 1970 to 2015. **Scientific Data**, v. 5, n. 1, p. 180045, 2018.

DOUGHTY, R. *et al.* Global GOSAT, OCO-2, and OCO-3 solar-induced chlorophyll fluorescence datasets. *Earth System Science Data*, v. 14, n. 4, p. 1513–1529, 2022.

EUROPEAN ENVIRONMENT AGENCY (EEA). *Atmospheric greenhouse gas concentrations*. Copenhagen: EEA, 2025. Disponível em: <https://www.eea.europa.eu>. Acesso em: 26 abr. 2026.

FAOSTAT. Crops and livestock products. 2024. Disponível em: <https://www.fao.org/faostat/en/#data/QCL>. Acesso em: 7 out. 2024.

FARHATE, C. V. V.; SOUZA, Z. M. D.; OLIVEIRA, S. R. D. M.; CARVALHO, J. L. N.; SCALA JÚNIOR, N. L.; SANTOS, A. P. G. Classification of soil respiration

in areas of sugarcane renewal using decision tree. *Scientia Agricola*, v. 75, n., p. 216-224, 2018.

FENG, L.; et al. Consistent regional fluxes of CH₄ and CO₂ inferred from GOSAT proxy XCH₄ : XCO₂ retrievals, 2010-2014. *Atmospheric Chemistry and Physics*, v. 17, n. 7, p. 4781-4797, 2017.

FERRACIOLLI, M. A.; BOCCA, F. F.; RODRIGUES, L. H. A. Neglecting spatial autocorrelation causes underestimation of the error of sugarcane yield models. *Computers and Electronics in Agriculture*, v. 161, n., p. 233-240, 2019.

FERREIRA BARBOSA, Maria Lucia *et al.* Compound impact of land use and extreme climate on the 2020 fire record of the Brazilian Pantanal. **Global Ecology and Biogeography**, v. 31, n. 10, p. 1960–1975, 7 out. 2022.

FRANKENBERG, Christian et al. New global observations of the terrestrial carbon cycle from GOSAT: Patterns of plant fluorescence with gross primary productivity. **Geophysical Research Letters**, v. 38, n. 17, 2011.

FREITAS, L. P. S. et al. Forecasting the spatiotemporal variability of soil CO₂ emissions in sugarcane areas in southeastern Brazil using artificial neural networks. *Environmental Monitoring and Assessment*, v. 190, n. 12, p. 741, 2018.

FUNK, Roger et al. From potential to implementation: an innovation framework to realize the benefits of soil carbon. In: *Soil carbon: Science, management and policy for multiple benefits*. Wallingford UK: CABI, 2015. p. 47-59.

GAROFALO, Danilo F. Trovo *et al.* Land-use change CO₂ emissions associated with agricultural products at municipal level in Brazil. **Journal of Cleaner Production**, v. 364, p. 132549, set. 2022.

GATTI, Luciana V. et al. Amazonia as a carbon source linked to deforestation and climate change. **Nature**, v. 595, n. 7867, p. 388-393, 2021.

GWA - GLOBAL WIND ATLAS. Globalwindatlas.info. Disponível em: <https://globalwindatlas.info/en/?_x_tr_hist=true>. Acesso em: 8 jun. 2026.

GOLKAR, Foroogh *et al.* Using OCO-2 Satellite Data for Investigating the Variability of Atmospheric CO₂ Concentration in Relationship with Precipitation, Relative Humidity, and Vegetation over Oman. *Water*, v. 12, n. 1, 2020.

GUARENGHI, M. M. et al. Land Use Change Net Removals Associated with Sugarcane in Brazil. *Land*, v. 12, n. 3, p. 584, 2023.

HAKKARAINEN, J.; IALONGO, I.; TAMMINEN, J. Direct space-based observations of anthropogenic CO₂ emission areas from OCO-2. *Geophysical Research Letters*, v. 43, n. 21, p. 11,400-411,406, 2016.

HANSEN, Gerrit; STONE, Dáithí. Assessing the observed impact of anthropogenic climate change. **Nature Climate Change**, v. 6, n. 5, p. 532–537, 21 maio 2016.

HEDELIUS, Jacob K. et al. Southern California megacity CO₂, CH₄, and CO flux estimates using ground-and space-based remote sensing and a Lagrangian model. **Atmospheric Chemistry and Physics**, v. 18, n. 22, p. 16271-16291, 2018.

HENGL, T. et al. SoilGrids250m: Global gridded soil information based on machine learning. **PLoS one**, v. 12, n. 2, p. e0169748, 2017.

HENGL, T.; NUSSBAUM, M.; WRIGHT, M. N.; HEUVELINK, G. B. M.; GRÄLER, B. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, v. 6, n., p. e5518, 2018.

HEUVELINK, G. B. M. et al. J. Machine learning in space and time for modelling soil organic carbon change. *European Journal of Soil Science*, v., n., p., 2020.

HOOGENDOORN, Gea; SÜTTERLIN, Bernadette; SIEGRIST, Michael. The climate change beliefs fallacy: the influence of climate change beliefs on the perceived consequences of climate change. **Journal of Risk Research**, v. 23, n. 12, p. 1577–1589, 1 dez. 2020.

HOU, T.; GENG, Y. J.; CHEN, J.; PAN, J. J.; HAASE, D.; LAUSCH, A. High-resolution digital mapping of soil organic carbon and soil total nitrogen using DEM derivatives, Sentinel-1 and Sentinel-2 data based on machine learning algorithms. *Science of the Total Environment*, v. 729, n., p., 2020.

IBGE. Instituto Brasileiro de Geografia e Estatística. Cidades e Estados do Brasil. Disponível em: <https://cidades.ibge.gov.br>. Acesso em: 17 nov. 2024.

IBGE. Instituto Brasileiro De Geografia E Estatística. Rebanho de Bovinos (Bois e Vacas). 2024. Disponível em: <https://www.ibge.gov.br/explica/producao-agropecuaria/bovinos/br>. Acesso em: 12 nov. 2024.

IBGE. Instituto Brasileiro de Geografia e Estatística. *Biomass e Sistema Costeiro-Marinho do Brasil*. Rio de Janeiro: IBGE, 2019. Disponível em: [IBGE – Biomass e Sistema Costeiro-Marinho do Brasil](#). Acesso em: 30 maio 2025.

Instituto Nacional de Pesquisas Espaciais (INPE). Estatísticas de queimadas – Bioma Pantanal. Programa Queimadas, 2026. Disponível em: https://data.inpe.br/queimadas/situacao_atual/situacao_atual/pages/estatisticas/?tipo=biomas&item=pantanal. Acesso em: 20 maio 2026.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change 2021 – The Physical Science Basis**. [S.l.]: Cambridge University Press, 2023.

IPCC - Climate Change 2022: Mitigation of Climate Change, Intergovernmental Panel on Climate Change. New York: Cambridge University Press, 2022. p. 1535.

IPCC. Summary for Policymakers. In: MASSON-DELMOTTE, V.; ZHAI, P.; PIRANI, A.; CONNORS, S. L.; PÉAN, C.; BERGER, S.; CAUD, N.; CHEN, Y.; GOLDFARB, L.; GOMIS, M. I.; HUANG, M.; LEITZELL, K.; LONNOY, E.; MATTHEWS, J. B. R.; MAYCOCK, T. K.; WATERFIELD, T.; YELEKÇİ, O.; YU, R.; ZHOU, B. (eds.). *Climate Change 2021: The Physical Science Basis*. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2021. p. 3–32.

LAWRENCE, Deborah; VANDECAR, Karen. Effects of tropical deforestation on climate and agriculture. **Nature Climate Change**, v. 5, n. 1, p. 27–36, 18 jan. 2015.

LI, XING; XIAO, JINGFENG; HE, BINBIN. Chlorophyll fluorescence observed by OCO-2 is strongly related to gross primary productivity estimated from flux towers in temperate forests. *Remote Sensing of Environment*, v. 204, p. 659–671, 2018.

LI, Zhaoxin *et al.* Generally Reduced Sink Capacity of Upland Soils for Atmospheric Methane Over the Past Three Decades (1993-2022). **Global change biology**, v. 31, p. e70248, 2025.

MAHMOUDZADEH, H.; MATINFAR, H. R.; TAGHIZADEH-MEHRJARDI, R.; KERRY, R. Spatial prediction of soil organic carbon using machine learning techniques in western Iran. *Geoderma Regional*, v. 21, n., p., 2020.

MAPBIOMAS. MapBiomas Project - Collection 6.0 of the Annual Series of Land Use and Land Cover Maps of Brazil. MCBRATNEY, A. B.; ODEH, I. O. A.; BISHOP, T. F. A.; DUNBAR, M. S.; SHATAR, T. M. Na overview of pedometric techniques for use in soil survey. *Geoderma*, v. 97, n. 3-4, p. 293-327, 2000.

MARIA, Luciano *et al.* **Spatiotemporal analysis of atmospheric XCH₄ as related to fires in the Amazon biome during 2015–2020**. *Remote Sensing Applications: Society and Environment*, v. 30, p. 100967, 1 abr. 2023.

MOHAMMED, G. H.; et al. J. **Remote sensing of solar-induced chlorophyll fluorescence (SIF) in vegetation: 50 years of progress**. *Remote Sensing of Environment*, v. 231, n., p. 111177, 2019.

NISBET, E. G. et al. Very Strong. **Atmospheric Methane Growth in the 4 Years 2014-2017: Implications for the paris Agreement**. *Global Biogeochemical Cycles*, v. 33, n. 3, p. 318-342, 2019.

OLIVEIRA, P. H. M. de; PANOSSO, A. R.; TREVELIM, L. F. **Variabilidade espaçotemporal da emissão de gases de efeito estufa e sua relação com a**

pecuária no brasil. In: Anais do XXXVI Congresso de Iniciação Científica da Unesp: "Ciência em tempos de crise climática e social". Anais...Águas de Lindóia (SP) Hotel Bendito Cacao Family Resort, 2024.

PARKER, R.; BOESCH, H. University of Leicester GOSAT Proxy XCH₄ v9.0. Centre for Environmental Data Analysis, 07 maio 2020. Disponível em: <https://doi.org/10.5285/18ef8247f52a4cb6a14013f8235cc1eb>.

PINHEIRO, Lucas Lima; NISE, Felipe de Abreu; SOBRINHO, Osvaldo Esteves. COMÉRCIO EXTERIOR, AGRONEGÓCIO E SUSTENTABILIDADE: DESAFIOS E OPORTUNIDADES PARA UMA PRODUÇÃO GLOBAL RESPONSÁVEL. Revista Ibero-Americana de Humanidades, Ciências e Educação, [S. l.], v. 11, n. 11, p. 7359–7366, 2025. DOI: 10.51891/rease.v11i11.22636. Disponível em: <https://periodicorease.pro.br/rease/article/view/22636>. Acesso em: 6 dez. 2025.

POSIT TEAM. *RStudio: Integrated Development Environment for R*. Boston: Posit Software, PBC, 2025. Disponível em: <http://www.posit.co/>.

POTENZA, R. F. *et al.* Análise das emissões de gases de efeito estufa e suas implicações para as metas climáticas do Brasil / 1970-2021. 2023.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2024. Disponível em: <https://www.r-project.org/>.

REICHSTEIN, M.; CAMPS-VALLS, G.; STEVENS, B.; JUNG, M.; DENZLER, J.; CARVALHAIS, N.; PRABHAT Deep learning and process understanding for data-driven Earth system science. *Nature*, v. 566, n. 7743, p. 195-204, 2019.

RESHI, A. R.; PICHUKA, S.; TRIPATHI, A. Applications of Sentinel-5P TROPOMI Satellite Sensor: A Review. *IEEE Sensors Journal*, v. 24, n. 13, p. 20312–20321, 2024.

RIBEIRO, Wagner Costa. Impactos das mudanças climáticas em cidades no Brasil. **Parcerias estratégicas**, v. 27, p. 297-321, 2008.

SANCHES, G. M.; GRAZIANO MAGALHÃES, P. S.; JUNQUEIRA FRANCO, H. C. Site-specific assessment of spatial and temporal variability of sugarcane yield related to soil attributes. *Geoderma*, v. 334, n., p. 90-98, 2019.

SANTOS, Cárilton Vieira dos; OLIVEIRA, Aryeverton Fortes de; FERREIRA FILHO, Joaquim Bento de Souza. Potential impacts of climate change on agriculture and the economy in different regions of Brazil. **Revista de Economia e Sociologia Rural**, v. 60, n. 1, 2022.

SANTOS, H. G. dos *et al.* **Sistema Brasileiro de Classificação de Solos**. 6. ed. rev ed. Brasília, DF: Embrapa, 2025. 393 p.

SEEG - Sistema de Estimativa de Emissões e Remoções de Gases de Efeito Estufa (SEEG), Observatório do Clima (OC). Análise das emissões de gases de efeito estufa e suas implicações para as metas climáticas do Brasil (1970–2024). Coleção 13, 2025. Disponível em: seeg.eco.br

SEEG - Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa. Análise das emissões brasileiras de Gases de Efeito Estufa e suas implicações para as metas climáticas do Brasil 1970- 2020. Observatório do Clima, 2021. 40 p.

SEEG - Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa. Emissões de GEE do Brasil e suas implicações para políticas públicas e a contribuição brasileira para o Acordo de Paris. Observatório do Clima, 2018. 80 p.

SEIDEL, E. J.; OLIVEIRA, M. S. DE. Novo índice geoestatístico para a mensuração da dependência espacial. *Revista Brasileira de Ciência do Solo*, v. 38, n. 3, p. 699–705, maio 2014.

SHADRIN, D.; PUKALCHIK, M.; KOVALEVA, E.; FEDOROV, M. Artificial intelligence models to predict acute phytotoxicity in petroleum contaminated soils. *Ecotoxicology and Environmental Safety*, v. 194, n., p., 2020

SILVA JUNIOR, Carlos Antonio da *et al.* Fires Drive Long-Term Environmental Degradation in the Amazon Basin. **Remote Sensing**, v. 14, n. 2, p. 338, 12 jan. 2022.

SILVA, Libério Junio et al. Predominantly positive XCO₂ anomalies in the Caatinga biome highlight carbon vulnerability. **Scientific Reports**, 2026.

SOUZA, C. M. et al. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. *Remote Sensing*, v. 12, n. 17, p. 2735, 2020.

STACKHOUSE, Paul W. et al. Prediction of Worldwide Energy Resource (POWER)-Agroclimatology methodology-(1.0 latitude by 1.0 longitude spatial resolution). Hampton, NASA Langely Research Center, 2015.

USDA - ESTADOS UNIDOS. Department of Agriculture. Foreign Agricultural Service. Production, supply and distribution: custom query. Disponível em: <https://apps.fas.usda.gov/psdonline/app/index.html#/app/advQuery>. Acesso em: 20 nov. 2025.

VIEIRA, Adriana Carvalho Pinto; LUNAS, Divina Aparecida Leonel; LEMES, Fernando Lobo. Política Pública e Sustentabilidade para o Agronegócio e Agricultura Familiar: O potencial do Agronegócio Brasileiro no Mercado de Carbono. In: Pesquisa, Desenvolvimento e Inovação na Era do Conhecimento. [S.l.]: AYA Editora, 2025. p. 159–180.

VIEIRA, SIDNEY ROSE et al. Geoestatística em estudos de variabilidade espacial do solo. Tópicos em ciência do solo. Viçosa: Sociedade Brasileira de Ciência do Solo, v. 1, p. 1-53, 2000.

WARNER, D. L.; BOND-LAMBERTY, B.; JIAN, J.; STELL, E.; VARGAS, R. Spatial Predictions and Associated Uncertainty of Annual Soil Respiration at the Global Scale. *Global Biogeochemical Cycles*, v. 33, n. 12, p. 1733-1745, 2019.

WORLD METEOROLOGICAL ORGANIZATION (WMO). State of the Global Climate 2024. Geneva: WMO, 2025. Disponível em: <https://public.wmo.int>. Acesso em: 26 abr. 2026.

