

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

BRUNA LÜDTKE PAIM

**ESTIMATIVA DE GASES DE EFEITO ESTUFA EM ÁREA DE EXTRAÇÃO DE CARVÃO
MINERAL E EMPREENDIMENTOS TERMELÉTRICOS – CANDIOTA/RS**

PORTO ALEGRE

2024

BRUNA LÜDTKE PAIM

**ESTIMATIVA DE GASES DE EFEITO ESTUFA EM ÁREA DE EXTRAÇÃO DE CARVÃO
MINERAL E EMPREENDIMENTOS TERMELÉTRICOS – CANDIOTA/RS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de doutor em Sensoriamento Remoto e Geoprocessamento.

Orientador: Profa. Dra. Rita de Cássia Marques Alves

PORTO ALEGRE

2024

CIP - Catalogação na Publicação

Paim, Bruna Lüdtke
ESTIMATIVA DE GASES DE EFEITO ESTUFA EM ÁREA DE
EXTRAÇÃO DE CARVÃO MINERAL E EMPREENDIMENTOS
TERMELÉTRICOS - CANDIOTA/RS / Bruna Lüdtke Paim. --
2024.
97 f.
Orientador: Rita de Cássia Marques Alves.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,
BR-RS, 2024.

1. Sensoriamento Remoto. 2. Carbono. 3. Mineração.
4. Termelétrica. I. Alves, Rita de Cássia Marques,
orient. II. Título.

AGRADECIMENTOS

À Deus, por ter me proporcionado tudo que tenho de mais valioso: saúde e uma família maravilhosa.

À pessoa mais importante da minha vida, minha mãe, Edília Gehrke Lüdtke, pelo amor incondicional, educação, carinho, apoio e compreensão, especialmente nos momentos mais difíceis.

À minha irmã, Bianca Lüdtke Paim, pelo amor, pela amizade de sempre e pelo ombro amigo.

Ao meu noivo, Rogério de Freitas Sonemann, pelo companheirismo e auxílio, pela paciência e compreensão e por seu amor e carinho que muito me ajudaram durante todo o doutorado.

À minha dupla, Bianca Dutra de Lima, por ter sido elemento chave na execução deste trabalho, por ser minha parceira de pesquisa, por me compreender e por dividir todas as angústias e alegrias que só o doutorado pode proporcionar.

Aos meus colegas do Laboratório de Meteorologia e Qualidade do Ar que me acolheram ao longo desses 4 anos, Arthur, Maiquel, Jonatha, Joshua, Leonardo e Ricardo que participaram, em vários momentos, da construção desse estudo.

À professora Rita de Cássia Marques Alves por me orientar, e contribuir no meu crescimento acadêmico, pela paciência, dedicação, pelos ensinamentos transmitidos e pelas contribuições inestimáveis na construção desse trabalho e em minha formação.

A todos os professores e funcionários do Programa de Pós-Graduação em Sensoriamento Remoto, pelos ensinamentos e contribuições para a formação profissional e pessoal de todos os alunos.

Ao Grupo de Pesquisa *Soil Management and Low Carbon Agriculture* (SOMALCA/UFRGS) que cedeu equipamentos, auxiliou nas análises das amostras de vegetação, solo e gases e pelo apoio pós análises, vocês foram fundamentais para a execução deste trabalho.

À CAPES pela concessão da bolsa de pesquisa.

À Universidade Federal do Rio Grande do Sul pelo espaço de formação e pelas experiências enriquecedoras.

RESUMO

O dióxido de carbono (CO₂) e o metano (CH₄) são os principais gases de efeito estufa emitidos por fontes antropogênicas. Por terem uma influência significativa na temperatura da superfície terrestre, esses gases são alvo de diferentes estratégias de mitigação que visam reduzir suas emissões. Considerando o grande volume de emissões das usinas termelétricas e das áreas de mineração de carvão, as regiões impactadas estão recebendo maior atenção em termos ambientais. O objetivo desta Tese foi quantificar o carbono estocado por ecossistemas adjacentes A áreas de extração de carvão e empreendimentos termelétricos, bem como a emissão de gases de efeito estufa por esses fragmentos florestais. Analisou-se os padrões de cobertura do solo obtidos por meio do Índice de Vegetação da Diferença Normalizada (NDVI), e realizou-se a classificação supervisionada em áreas impactadas por esses empreendimentos, relacionando-as com as emissões de gases de efeito estufa a partir de dados de sensoriamento remoto. Os resultados apontaram relação entre a distribuição de biomassa e carbono com a distribuição de atividades agrícolas e de energia, sendo estas as regiões que apresentam valores mais elevados de metano. Também quantificou-se o carbono armazenado nas áreas adjacentes aos empreendimentos termelétricos e áreas de mineração. Os resultados das variáveis biofísicas coletadas no campo mostram que a variação da biomassa e do carbono foi diferente nos diversos locais de amostragem, possivelmente devido ao manejo do solo e da vegetação em cada local. No sentido de integrar os fluxos terrestres e atmosféricos, também quantificamos o carbono emitido pelo solo, a fim de investigar o balanço de carbono terrestre. No geral, os resultados demonstram que a estrutura do solo no entorno da área de mineração é fortemente devastada e a proximidade com a termelétrica também afeta os fluxos de carbono. Há diferenças nos comportamentos dos gases de efeito estufa nos pontos amostrais sendo a maior emissão de CO₂ na área mais próxima à termelétrica e a maior absorção de CH₄ neste mesmo ponto. Este estudo mostra que a coleta de dados *in situ* é de suma importância para analisar e quantificar padrões de emissão e absorção de gases de efeito estufa em áreas relacionadas às atividades de mineração e queima de carvão mineral.

Palavras-chave: Sensoriamento Remoto. Carbono. Mineração.

ABSTRACT

Carbon dioxide (CO₂) and methane (CH₄) are the main greenhouse gases emitted by anthropogenic sources. Because they have a significant influence on the temperature of the Earth's surface, these gases are the focus of different mitigation strategies aimed at reducing their emissions. Considering the large volume of emissions from thermal power plants and coal mining areas, the impacted regions are receiving greater attention in environmental terms. The aim of this thesis was to quantify the carbon stored by ecosystems adjacent to coal mining areas and thermal power plants, as well as the greenhouse gas emissions from these forest fragments. Land cover patterns were analyzed using the Normalized Difference Vegetation Index (NDVI), and supervised classification was carried out in areas impacted by these projects, relating them to greenhouse gas emissions using remote sensing data. The results showed a relationship between the distribution of biomass and carbon and the distribution of agricultural and energy activities, these being the regions with the highest methane values. The carbon stored in areas adjacent to thermoelectric projects and mining areas was also quantified. The results of the biophysical variables collected in the field show that the variation in biomass and carbon was different at the various sampling sites, possibly due to the treatment of the soil and vegetation at each site. To integrate terrestrial and atmospheric fluxes, we also quantified the carbon emitted by the soil in order to investigate the terrestrial carbon balance. Overall, the results show that the soil structure around the mining area is heavily devastated and the proximity to the thermal power plant also affects carbon fluxes. There are differences in the behavior of the greenhouse gases at the sampling points, with the highest CO₂ emissions in the area closest to the thermoelectric plant and the highest CH₄ absorption at the same point. This study shows that in situ data collection is extremely important for analyzing and quantifying greenhouse gas emission and absorption patterns in areas related to coal mining and burning activities.

Keywords: Remote Sensing. Carbon. Mining.

LISTA DE TABELAS

Tabela 1 - Equações alométricas para estimativa de biomassa florestal.....	15
Tabela 2 - Intervalo de aceitação dos resultados do Índice Kappa (LANDIS e KOCH, 1977)	26

LISTA DE FIGURAS

Figura 1 - Área de estudo com destaque para as UTEs e áreas de mineração consideradas no estudo.....	25
Figura 2 - Composição vegetal dos pontos amostrais (a) Ponto 1 (Fazenda Copelmi), (b) Ponto 2 (Mina - CRM) e (c) Ponto 3 (Sítio – UTE).....	27
Figura 3 - Metodologia aplicada para posterior obtenção de biomassa e carbono dos pontos amostrais. (1) coleta da vegetação por meio do método do quadrado; (2) pesagem da vegetação antes e após secagem em estufa; (3) moagem das amostras em moinho e posterior em cilindro, (4) preparo das amostras para envio laboratorial.	28
Figura 4 – Metodologia aplicada para obtenção dos fluxos de CO ₂ e CH ₄ no solo, (1) base metálica preenchida com água; (2) câmara instalada para coleta das amostras de gás; (3) coleta das amostras; (4) transferência das amostras coletadas em campo para os vials e armazenamento até serem enviadas ao laboratório para análise.	29
Figura 5 – Metodologia aplicada para obtenção do carbono orgânico total do solo nos três pontos amostrais. (1) coleta das amostras de solo com uso de trado holandês; (2) preparo das amostras para secagem em estufa; (3) passagem das amostras secas em peneira e moídas em gral de ágata; (4) preparo das amostras para envio ao laboratório.....	30

SUMÁRIO

ORGANIZAÇÃO DA TESE	10
1 INTRODUÇÃO	11
1.1 Hipótese	12
1.2 Objetivos	13
2 DESENVOLVIMENTO	14
2.1 Referencial teórico	14
2.1.1 <i>Biomassa e Carbono</i>	14
2.1.2 <i>Estimativa de Biomassa e Carbono (através de CO₂ e CH₄) por meio de técnicas de sensoriamento remoto</i>	15
2.1.3 <i>Trocas gasosas entre superfície terrestre e atmosfera</i>	20
2.1.4 <i>Empreendimentos Termelétricos</i>	21
2.1.5 <i>Processo de exploração de carvão mineral</i>	22
2.2 Metodologia	24
2.2.1 <i>Localização e caracterização da área de estudo</i>	24
2.2.2 <i>Mapeamento da área a partir de Análise de Imagens Baseada em Objetos Geográficos</i> 26	
2.2.3 <i>Experimento de campo</i>	27
2.2.4 <i>Estimativa do estoque de Carbono em superfície</i>	31
2.3 Resultados e discussões	32
2.3.1 <i>Artigo 1: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto em área sob influência de empreendimentos termelétricos e mineração</i>	33
2.3.2 <i>Artigo 2: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D.; FONTANA, D. C.; MORAES, O. L. L. Assessment of the relationship between biomass and carbon near coal mining and combustion areas.</i> 47	
2.3.3 <i>Artigo 3: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. BAYER, C.; CAUMO, M. CO₂ and CH₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining</i>	69
3 CONCLUSÕES	88
4 CONSIDERAÇÕES FINAIS	90
FINANCIAMENTO	91
REFERÊNCIAS	92

ORGANIZAÇÃO DA TESE

A Tese foi elaborada de acordo com a política e os procedimentos do PPGSR da Universidade Federal do Rio Grande do Sul com a inclusão de artigo publicado e submetidos. Este documento é composto por três capítulos, um capítulo introdutório, em seguida apresenta o referencial teórico e três artigos e por fim, fechamento do estudo.

O capítulo 1 é composto pela introdução geral da Tese, contemplando além da introdução, os objetivos e a hipótese.

O capítulo 2 são abordadas as principais bases teóricas compreendendo principalmente o emprego do sensoriamento remoto e a coleta de dados *in situ* para estimativa de biomassa e carbono na vegetação e nos solos, sendo o objeto de estudo áreas impactadas por mineração e combustão de carvão, bem como a metodologia empregada nesta pesquisa. Neste mesmo capítulo são apresentados os três artigos que compõem os resultados e discussão desta Tese.

- Artigo 1: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto em área sob influência de empreendimentos termelétricos e mineração.
<https://doi.org/10.26848/rbgf.v17.2.p1362-1374>
- Artigo 2: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D.; FONTANA, D. C.; MORAES, O. L. L. Assessment of the relationship between biomass and carbon near coal mining and combustion areas.
- Artigo 3: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D.; BAYER, C.; CAUMO, M. CO₂ and CH₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining.

Os capítulos 3 e 4 apresentam as considerações finais da Tese.

1 INTRODUÇÃO

As mudanças climáticas em geral têm preocupado muito a população mundial, pois advertem para um possível aumento global de eventos meteorológicos extremos (SANTOS *et al.*, 2011). Diante das incertezas do futuro climático do planeta, no ano de 1988 foi criado pelo Programa Ambiental da Organização das Nações Unidas (UNEP) e pela Organização Mundial de Meteorologia (OMM), o Painel Intergovernamental de Mudanças Climáticas (IPCC). O IPCC considera cenários futuros e, por meio de análises de informações científicas e dos resultados decorrentes de tais cenários, fornece um entendimento das potenciais mudanças do clima e dos respectivos impactos ambientais e socioeconômicos causados por tais mudanças. Há dois tipos principais de cenários: o de baixas emissões antropogênicas (otimista) e o de altas emissões (pessimista). O IPCC se encontra no seu sexto Relatório de Avaliação dos impactos das mudanças climáticas que leva em consideração principalmente os impactos dessas mudanças nos ecossistemas, na biodiversidade e nas comunidades animais e humanas e sua capacidade de se adaptarem às mudanças climáticas (IPCC, 2022).

Atualmente existem muitos projetos e trabalhos desenvolvidos e em desenvolvimento para a região Amazônica, por ela ser umas das áreas de maior impacto ambiental, devido ao aumento do desmatamento, que acarreta a liberação de dióxido de carbono (CO₂) e aumento da temperatura do ar (SANTOS *et al.* 2024); as queimadas, que além de aumentarem as emissões de CO₂ para a atmosfera, podem afetar a atividade de descargas atmosféricas (raios) por meio de interações entre partículas de aerossóis e nuvens (NETO *et al.* 2023); e perda de biodiversidade consequência da degradação e perda florestal por desmatamento (AZUERO-PEDRAZA *et al.*, 2024). Romero *et al.* (2020) ajustaram, para estimar volume, biomassa e carbono em árvores comerciais no sudoeste da Amazônia, equações alométricas a partir da comparação de múltiplos modelos lineares e não lineares buscando uma equação específica para a região, visto que as equações já existentes para outras regiões não a quantificavam de forma correta. David *et al.* (2022) apresentam um aplicativo de estimativa de biomassa e carbono florestal utilizando como dados de entrada variáveis provenientes de quatro formações florestais brasileiras, e comparam os resultados obtidos com outras abordagens encontradas na literatura para estas estimativas. Fawcett *et al.* (2023), por meio de dados de estimativa de carbono e biomassa derivadas de imagens do satélite *L-Band Vegetation Optical Depth* e mapas de cobertura florestal, modelaram as perdas (desmatamento) e ganhos (regeneração) de carbono em floresta entre 2011 e 2019. Rangel Pinagé *et al.* (2023), utilizando imagens do *PlanetScope*, implementaram uma

estrutura de classificação probabilística para identificação de florestas intactas, exploradas e queimadas em três locais da Amazônia, e também estimaram a biomassa para essas classes usando LiDAR aerotransportado, comparando as incertezas de biomassa a partir das estimativas derivadas do LiDAR.

Porém, existem outras áreas que podem fornecer informações bastante relevantes e ainda são pouco exploradas por estudos ambientais como, por exemplo, áreas impactadas por empreendimentos termelétricos e áreas de extração de carvão mineral. No estado do Rio Grande do Sul encontram-se em operação a Usina Termelétrica Presidente Médici (Fase C) e a Usina Termelétrica Pampa Sul, estando ainda em licenciamento novos empreendimentos termelétricos na região. Em regiões sob influência de usinas termelétricas e mineração há uma grande preocupação ambiental devido à queima de combustíveis fósseis e a emissão de gases na atmosfera. De maneira geral, esses processos geram emissões de gases de efeito estufa (GEE), principalmente dióxido de carbono (CO_2) e metano (CH_4) (PARANÁIBA *et al.*, 2018). Apesar de muitos estudos descreverem estes fluxos de gases estufa ainda há uma escassez de análises que compreendam os diferentes compartimentos, avaliando não somente as emissões de carbono (C) à atmosfera, mas também outros processos ecológicos como a incorporação na biomassa dos fragmentos florestais nas adjacências. No sentido de integrar os fluxos terrestre (biosfera) e a atmosfera, o presente trabalho propõe, quantificar o carbono emitido, tanto pela extração do carvão mineral quanto pelas termelétricas e o quanto é estocado pelo meio ambiente e com isso gerar um modelo de estimativa de biomassa e taxas de incorporação de C nos fragmentos florestais a partir de imagens de índices de vegetação. Com essa abordagem pretende-se investigar o balanço de carbono terrestre empregando técnicas de sensoriamento remoto e geoprocessamento para estudar os processos atmosfera-biosfera em regiões influenciadas por empreendimentos termelétricos e áreas de exploração de carvão a céu aberto.

1.1 Hipótese

Parte-se do pressuposto de que a exploração de carvão mineral e empreendimentos termelétricos impactam áreas campestres em suas adjacências, afetando as concentrações de gases de efeito estufa nessas regiões; e que a avaliação dos processos de incorporação de carbono por essas áreas seja possível de ser quantificada a partir do estabelecimento de uma metodologia que incorpore medições *in situ* e sensoriamento remoto.

1.2 Objetivos

Esta pesquisa tem como objetivo principal quantificar o carbono estocado por ecossistemas adjacentes a áreas de extração do carvão mineral e empreendimentos termelétricos no município de Candiota - RS, bem como a emissão de gases de efeito estufa por esses fragmentos campestres, buscando gerar um modelo de estimativa de biomassa e taxas de incorporação de carbono.

Os objetivos específicos são:

1. Analisar os padrões de cobertura do solo obtidos por meio de índices de vegetação;
2. Realizar a classificação supervisionada em áreas impactadas por empreendimentos termelétricos e mineração, relacionando-as com as emissões de gases de efeito estufa a partir de dados de sensoriamento remoto;
3. Avaliar os fluxos terrestres e quantificar o estoque de gases e de biomassa por fragmentos campestres;
4. Desenvolver um modelo para estimar as taxas de incorporação de biomassa e carbono em pastagens naturais e plantadas próximas a projetos termelétricos e de mineração de carvão;
5. Integrar os fluxos terrestres (biosfera) e a atmosfera, e quantificar o carbono emitido pelo solo;
6. Investigar o balanço de carbono terrestre para estudar os processos atmosfera-biosfera em regiões influenciadas por empreendimentos termelétricos.

2 DESENVOLVIMENTO

2.1 Referencial teórico

2.1.1 Biomassa e Carbono

A biomassa é a quantidade de material de origem biológica, seja ela viva ou morta, animal ou vegetal (SANQUETTA e BALBINOT, 2004). Biomassa florestal é dividida em biomassa acima do solo e abaixo do solo, devido aos processos usados nas suas estimativas. Esta revisão abordará prioritariamente a biomassa acima do solo, identificada apenas como biomassa.

Há diferentes métodos de estimativa de biomassa, diretos e indiretos. Os métodos diretos são conhecidos como métodos destrutivos, pois ocorrem quando os componentes vegetais são separados e pesados em campo, onde é obtida a biomassa verde, e posteriormente em laboratório, quando as amostras dessa vegetação são secas em estufa para obter-se o teor de umidade, que servirá para identificação da biomassa seca, (subtração do teor de umidade da biomassa verde) (WATZLAWICK, 2003). Os métodos indiretos são baseados em métodos diretos e utilizam equações alométricas (equações que permitem estimar variáveis biofísicas de uma vegetação em função de medidas *in situ*), estabelecidas em variáveis dendométricas (altura, diâmetro e volume do tronco) ou dados de sensoriamento remoto (QURESHI *et al.* 2012).

As equações alométricas de biomassa podem ser equações lineares ou não lineares. A utilização de modelos não lineares é justificada devido ao comportamento não linear das variáveis naturais (SANTOS, 1996), porém apresenta algumas desvantagens pela maior complexidade de estimar seus parâmetros. Já os modelos lineares são modelos mais simples, e seus erros são facilmente minimizados através de métodos estatísticos. Na Tabela 1 são apresentados dois exemplos de equações alométricas para estimativa de biomassa florestal, sendo uma aritmética e outra logarítmica. Por outro lado, a estimativa de biomassa de vegetação não arbórea é realizada a partir do cálculo do estoque de carbono na vegetação, com base nos valores de matéria seca e úmida da amostra.

Tabela 1 - Equações alométricas para estimativa de biomassa florestal.

Equações Alométricas	Autor do Modelo
$Y = b_0 + b_1DAP^2 + b_2DAP^2H + \varepsilon_i$	Sanqueta <i>et al.</i> (2004)
$\ln Y = b_0 + b_1 \ln DAP + b_2 \ln H + \ln \varepsilon_i$	Higuchi <i>et al.</i> (1998)

onde: Y = biomassa da matéria seca total; DAP = diâmetro; H = altura; bi = coeficientes; ε = erro.

Fonte: Elaboração própria.

Métodos para estimativa de biomassa através de técnicas de sensoriamento remoto são eficientes, possuem ampla cobertura espacial e necessitam de dados sobre a biomassa florestal obtidos através de métodos diretos (destrutivos) (DONG *et al.* 2003).

A determinação dos valores de carbono fixados em grandes áreas de cobertura vegetal somente por métodos diretos se torna inviável, o que tem levado a um aumento do uso de técnicas de sensoriamento remoto para a estimativa desses valores (NEEFF *et al.* 2005). Devido à dificuldade de mensurar a biomassa abaixo do solo essas pesquisas focam apenas na biomassa acima do solo (LU, 2006) que representa cerca de 55% de carbono estocado em um ecossistema florestal (QURESHI *et al.* 2012).

2.1.2 Estimativa de Biomassa e Carbono (através de CO_2 e CH_4) por meio de técnicas de sensoriamento remoto

A biomassa vegetal, como dito anteriormente, pode ser estimada através do uso de sensoriamento remoto. Muitos trabalhos utilizam dessa técnica utilizando diferentes tipos de dados espectrais, como os obtidos através de sensores remotos ativos, que emitem sua própria energia; e sensores ópticos (passivos), não emitem energia, mas coletam a energia emitida ou refletida naturalmente pelo alvo. Diversos autores apresentam que o uso de dados ópticos de sensoriamento remoto associados a pesquisas de campo gera estimativas de biomassa e estoque de carbono de ótima precisão (BAKER *et al.* 2010, LE MAIRE *et al.* 2011).

Nos trabalhos já desenvolvidos há um destaque ao uso de índices de vegetação, que são propostos para explorar as características espectrais da planta, principalmente nas regiões espectrais do visível e infravermelho próximo. Esses índices são medidas sem unidades e resultado de transformações radiométricas a partir de bandas espectrais de imagens orbitais, e são utilizados para estimar e comparar dados biofísicos adquiridos em campo, como biomassa e carbono (SILVA, 2015).

Um dos índices mais amplamente utilizados na literatura é o Índice de Vegetação da Diferença Normalizada (NDVI – *Normalized Difference Vegetation Index*), que foi proposto por Rouse *et al.* (1973) para reduzir o impacto da dispersão/espalhamento atmosférico usando uma diferença normalizada entre duas bandas do espectro (THENKABAIL *et al.*, 2000): a do infravermelho próximo e a do vermelho (Equação 1). Os valores desse índice variam de -1 a +1, sendo os valores mais elevados indicadores de áreas com maiores Índices de Área Foliar (IAF) e os valores mais baixos indicadores de áreas com menor densidade de vegetação. O NDVI é um bom preditor de biomassa verde, tanto úmida quanto seca, porém satura em valores muito altos de IAF.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (1)$$

Onde:

ρ_{NIR} = reflectância banda espectral do infravermelho próximo

ρ_{RED} = reflectância banda espectral do vermelho

Visando suprir essa desvantagem apresentada no NDVI, Huete *et al.* (2002) desenvolveu o Índice de Vegetação Melhorado (EVI – *Enhanced Vegetation Index*) que otimiza o sinal da vegetação, o que melhora a sensibilidade de detecção em áreas com maiores valores de densidades de vegetação. Esse índice leva em consideração as mesmas componentes do NDVI em seu algoritmo, somadas aos fatores de ajuste do solo e coeficientes para ajuste do efeito da atmosfera, além de incluir a banda do azul (Equação 2).

$$EVI = \frac{G * \rho_{NIR} - \rho_{RED}}{\rho_{NIR} + C_1 * \rho_{RED} - C_2 * \rho_B + L} \quad (2)$$

Onde:

G = fator de ganho;

ρ_B = refletância banda espectral do azul;

L = ajuste de fundo do dossel vegetal;

C1 e C2 = coeficientes de ajuste da influência dos aerossóis.

Para a interferência de carbono, Gamon *et al.* (1992) propôs o Índice de Reflectância Fotoquímica (PRI - *Photochemical Reflectance Index*), que é sensível às mudanças nos pigmentos carotenoides na folhagem (ALMEIDA e ROCHA, 2018), o que funciona como um

indicativo da taxa de CO₂ armazenada pela folha por unidade de energia absorvida. O PRI é resultado da relação entre as bandas espectrais do verde e do azul (Equação 3).

$$PRI = \frac{\rho G - \rho B}{\rho G + \rho B} \quad (3)$$

Onde:

ρG = refletância banda espectral do verde.

O índice CO₂Flux surge então da relação do PRI com o NDVI, o que torna possível integrar as feições de absorção decorrentes do sequestro de carbono. Baptista (2003) ao utilizar esse índice para mapeamento e sequestro de carbono em ambientes tropicais ressaltou que os dados de PRI devem ser reescalados para valores positivos gerando um novo índice, o sPRI (Equação 4).

$$sPRI = \frac{PRI + 1}{2} \quad (4)$$

O índice espectral CO₂Flux é então obtido através da multiplicação do índice NDVI com o índice sPRI (Baptista, 2003) (Equação 5).

$$CO_2Flux = NDVI * sPRI \quad (5)$$

A partir do estudo de Baptista (2003), o CO₂Flux vêm sendo amplamente utilizado na mensuração de carbono em diferentes tipos de vegetação, correlacionando dados espectrais e biofísicos (MARTINS, 2013; SILVA, 2015; ALMEIDA *et al.*, 2018). Este método é amplamente utilizado para as estimativas de CO₂ por sensoriamento remoto, porém há outro importante gás de efeito estufa presente na atmosfera e que desempenha um importante papel nas mudanças climáticas: o metano (CH₄), que pode ser estimado em escala local e global, e resolução espacial relativamente alta.

Observações por sensoriamento remoto em escala global de CH₄ e também de CO₂ são possíveis desde 2002, através de medições de instrumentos hiperespectrais a bordo de alguns satélites como o Envisat, lançado em 2002 pela Agência Espacial Européia (ESA) que possui a bordo o sensor *SCanning Imaging Absorption spectroMeter for Atmospheric CartographY* (SCIAMACHY); o Aqua da NASA com o sensor AIRS (*Atmospheric Infrared Sounder*), também lançado em 2002; o *Greenhouse gases Observing SATellite* (GOSAT), lançado em 2009, que possui o sensor TANSO-FTS, que fornece observações globais de gases de efeito estufa de alta qualidade mas possui cobertura espacial bastante esparsa e quantifica, por uma média plurianual, as emissões de CH₄ em uma escala de 100-1000 km (JACOB *et al.*, 2016); o satélite LeoStar-2 que possui um único sensor a bordo, o *Orbiting*

Carbon Observatory-2 (OCO-2) da NASA, lançado em 2014 (FRANKENBERG *et al.*, 2015); e o mais recente, o Sentinel 5 Precursor (S5-P) com o sensor *TROPOspheric Monitoring Instrument* (TROPOMI), lançado em 2017, com resolução de 7x7 km², até agosto de 2019, e 7x5,5 km², a partir de agosto de 2019, que quantifica as emissões diárias de metano. De acordo com Magro *et al.* (2021), esse instrumento realiza observações nas regiões espectrais ultravioleta-visível (270–500 nm), infravermelho próximo (675–775 nm) e infravermelho de onda curta (SWIR - *Short-Wave Infrared*) (2305–2385 nm), que cobrem bandas de absorção de CH₄ e Oxygen-A (760 nm), que são utilizadas para obtenção da coluna de ar seco usada no cálculo das frações molares médias de ar seco da coluna de XCH₄ (LUDEWIG, 2023).

Nos últimos anos diversos estudos foram realizados utilizando dados espaciais de CH₄, como o de Kozicka *et al.* (2021), onde foram utilizados dados do sensor TROPOMI para dimensionar mudanças espaciais e temporais de metano sob áreas de cultivo de arroz irrigado, que são fortemente associadas a emissões deste gás. Neste e em outros trabalhos (ZHANG *et al.*, 2022; TRENCHÉV *et al.*, 2023) que utilizam dados do sensor TROPOMI, os dados da taxa média de mistura de ar seco da coluna de CH₄ (ppb) são os produtos de Nível 3 do satélite Sentinel-5P. O processamento dos dados geralmente envolve estatísticas de análise de correlação e autocorrelação espacial, como no estudo de Zhang *et al.* (2022), que correlacionaram a densidade populacional com os dados de concentração de CH₄.

Para detectar tendências a longo prazo e variações sazonais na concentração de CH₄ um modelo de tendência linear, já utilizado para detecção de tendência de outros componentes atmosféricos, é aplicado ao CH₄ com uso de dados de sensoriamento remoto (WU *et al.*, 2019) (Equação 6):

$$Y_i = A + BX_i + C\sin(DX_i + E) + M_i \quad (6)$$

Onde:

Y_i = concentração mensal de CH₄ (ppb/mês);

X_i = número de meses;

M_i = resíduo (diferença entre o modelo e os valores medidos);

A, B, C, D e E = parâmetros de ajuste;

$A + BX_i$ = função linear que representa a tendência linear das concentrações de CH_4 durante o período a ser analisado, A representa o valor no início do período e B é a mudança na inclinação dos valores mensais;

$C \sin(DX_i + E)$ = componente sazonal da concentração anual, C representa a amplitude, D frequência (fixado em $\pi/6$, pois é necessário, no mínimo, o período de um ano) e E mudança de fase.

Medições do sensor AIRS e TROPOMI e do satélite GOSAT também são amplamente utilizadas para analisar e monitorar a distribuição e transmissão das concentrações de CH_4 na atmosfera na China (YANG *et al.*, 2017; WU *et al.*, 2019; ZHANG *et al.*, 2022). Estes sensores possuem uma contribuição significativa para estudos de fluxos de carbono, porém por serem sensores passivos, as medições sofrem influência de camadas de aerossóis presentes na atmosfera e de finas nuvens de gelo, que posteriormente necessitam ser corrigidas por complexos algoritmos de recuperação. Para mitigar essa limitação dos sensores passivos, o satélite franco-alemão MERLIN (*Methane Remote Sensing Lidar Mission*) (PIERANGELO *et al.*, 2016), com data de lançamento prevista para 2024, terá a bordo um sensor ativo para medição de CH_4 , o *Lidar Methane Integrated Path Differential Absorption* (IPDA), que medirá as concentrações globais de metano para quantificar e localizar fontes de emissão e compreender melhor sua variação.

Em escala local existem campanhas que utilizam sensores espectrais de alta resolução espacial, como o radiômetro LHR (*Laser Heterodyne Radiometer*), acoplados a lasers de diodo operando na região espectral NIR para realizar medições da coluna e da razão de mistura de ar seco de CO_2 e CH_4 atmosféricos (WANG *et al.*, 2020). Uma campanha experimental assim ocorreu na China durante 6 meses e os dados obtidos foram validados com dados do Satélite GOSAT. A campanha CO_2 e Metano (CoMet) realizada em 2018 na Bacia de Carvão da Alta Sibéria no sul da Polônia (KRAUTWURST *et al.*, 2021), através do instrumento *Methane Airborne MAPper* (MAMAP) de sensoriamento remoto passivo, obteve medições da coluna de CO_2 e CH_4 em escala regional, o que permitiu o fornecimento de dados de gases de efeito estufa (FIX *et al.*, 2018) em um dos maiores pontos de emissão de CH_4 da Europa (KRAUTWURST *et al.*, 2021).

As medições da concentração de carbono na atmosfera por sensoriamento remoto no espaço fornecem informações para avaliar mudanças espaciais e temporais da concentração de gases de efeito estufa em escala global, o que compensa a deficiência de medições mais próximas a superfície terrestre (WU *et al.*, 2019).

2.1.3 Trocas gasosas entre superfície terrestre e atmosfera

A técnica com uso de câmara de solo estática que contabiliza somente o fluxo de carbono do solo, consiste em delimitar uma pequena área contendo vegetação ou não utilizando uma câmara e desta forma restringir a circulação de ar em seu interior no momento da realização das medidas da variação na concentração de gases (COSTA *et al.*, 2006). A coleta das amostras por esta técnica se dá de forma manual, e posteriormente o material coletado é enviado para análise laboratorial ou quantificado *in situ* através do uso de modelos automáticos. Ambos tratamentos utilizam analisador por infravermelho ou cromatografia gasosa (COSTA *et al.*, 2006). As câmaras podem ser fechadas ou abertas (COSTA *et al.*, 2006), sendo mais comum o uso das câmaras fechadas por não haver a renovação do ar e assim as mudanças de concentração do gás serem contínuas (DENMEAD *et al.*, 1993).

A confecção das câmaras manuais deve ser realizada de forma padronizada e com materiais que minimizem o máximo possível as interações com o ambiente externo. Alguns cuidados devem ser tomados durante as coletas, armazenamento e transporte das amostras para evitar ou ao menos reduzir erros e possíveis contaminações, dentre eles: a realização das coletas em um período do dia que represente a média diária do dia, geralmente entre 9:00 – 11:00 horas como horário médio local (MINAMIKAWA *et al.*, 2012); pré-evacuação de frascos de vidro (*Vials*) utilizados para armazenamento das amostras e manutenção destes a baixa temperatura até a análise; não perturbação do solo e plantas em torno e no interior das câmaras durante todo o período de coletas (tanto no ato da coleta como nos dias anteriores e posteriores).

Medições de fluxos por este método foram empregadas em diferentes culturas, como arroz, trigo, soja, milho, aveia, entre outras. Costa *et al.* (2008) ao aplicarem esse método para a cultura de arroz irrigado quantificaram a emissão média diária de CH₄ e identificaram uma emissão entre 25,6 e 11 mg CH₄ m⁻² h⁻¹. Yao *et al.* (2009) compararam o uso de câmaras manuais e automáticas para medição dos fluxos de N₂O (óxido nitroso), CO₂ e CH₄ em um sistema de cultivo rotacional de arroz-trigo, e identificaram que ambos os métodos são adequados para medições diárias e sazonais desses fluxos. Piva *et al.* (2014) avaliaram o impacto da integração lavoura-pecuária, utilizando a metodologia de câmaras estáticas, identificaram que os fluxos de CH₄ não foram afetados pelos sistemas de manejo do solo e que não ocorreu sequestro de carbono orgânico do solo suficiente para compensar as emissões de N₂O. Veeck *et al.* (2018) ao realizarem uma análise dos fluxos noturnos de CO₂ do solo em área de cultivo de soja, por meio do método de câmara

automática e com o método de Covariância dos vórtices turbulentos, identificaram que a umidade do solo é um fator importante no controle das emissões de CO₂ e que o fluxo acumulado é maior no solo do que na atmosfera. Amadori et al. (2022), com o objetivo de avaliar as emissões de N₂O e CH₄ do solo em um sistema rotacional de milho-aveia, identificaram um consumo anual de CH₄, cerca de -1,82 kg CH₄ ha⁻¹ que compensou aproximadamente 1,4% da emissão de N₂O.

2.1.4 Empreendimentos Termelétricos

Uma usina termelétrica gera energia elétrica de duas formas: queima de combustível fóssil (não-renovável) ou biomassa (renovável). Essa queima de combustível aquece um volume de água que transforma-se em vapor, o qual gira uma turbina que aciona um gerador elétrico. Assim a eletricidade é gerada a partir da energia cinética obtida pela passagem do vapor d'água pela turbina que a transforma em energia elétrica.

Existem três tipos de combustíveis fósseis: petróleo, gás natural e carvão mineral ou natural. O carvão mineral é formado a partir da matéria orgânica de vegetais depositados em áreas conhecidas como bacias sedimentares e é responsável por aproximadamente 40% da energia gerada no mundo todo, o que representa mais de um terço da geração global de eletricidade (IEA, 2021). De acordo com o Relatório de Estatísticas e Informação de Carvão 2020 da *International Energy Agency* (IEA), a produção de carvão aumentou 1,5% em todo o mundo em 2019 e o consumo reduziu 1,2%. Na queima do combustível é liberada na atmosfera uma certa quantidade gás carbônico e água, e essa quantidade varia de acordo com as características do combustível utilizado. A emissão de CO₂ aumenta com o teor de carbono presente no combustível e com a quantidade queimada, o que representa a sua capacidade de geração de energia em Megawatt (MW). Licks (2010) coletou dados de diferentes termelétricas a carvão de capacidade instalada de 20 MW até 857 MW e suas respectivas emissões de carbono. Para uma capacidade de geração de energia de 20 MW, 446 MW e 857 MW, a emissão de carbono é de aproximadamente 27 Gg C ano⁻¹, 447 Gg C ano⁻¹ e 940 Gg C ano⁻¹, respectivamente (LICKS, 2010).

De acordo com dados da Agência Nacional de Energia Elétrica (ANEEL), no Brasil existem em operação dez usinas termelétricas movidas a carvão, a maioria localizada na região sul do país. Essa é uma região em destaque na produção de carvão devido a sua proximidade com jazidas como a Figueira-Sapopema (PR), Sul-Catarinense (SC), Santa Terezinha, Charqueadas, Baixo Jacuí e Candiota (RS) (GOMES *et al.*, 2003), sendo a de Candiota a

principal do país, correspondendo a cerca de 38% dos recursos totais de carvão brasileiro (BORBA, 2001; GOMES *et al*, 2003).

No município de Candiota – RS encontram-se em operação segundo a ANEEL, duas usinas termelétricas movidas a carvão: a Usina Termelétrica Candiota III (Fase C), operada pela Âmbar Energia, com potência instalada de 350 MW e em operação desde o ano de 2011; e a Usina Termelétrica Pampa Sul, operada pela Starboard e Perfin, com potência instalada de 345 MW e em operação desde 2019. Segundo dados da pesquisa realizada pela Sistema de Estimativas de Emissões Gases de Efeito Estufa (SEEG Brasil) o município emitiu no ano de 2018 mais de 2 milhões de toneladas de CO₂ através da queima de combustíveis, o que garante seu lugar entre os quinze primeiros na classificação geral dos municípios brasileiros que mais emitem CO₂ no setor de energia e o primeiro no estado do Rio Grande do Sul (SEEG, 2022).

O SEEG estima as emissões de GEE para todos os municípios brasileiros de forma simplificada, por isso indica as principais tendências de emissões nos diferentes setores, o que pode causar um distanciamento de resultados obtidos através de pesquisas, levantamentos e inventários locais (SEEG, 2022). De acordo com as diretrizes do IPCC para inventários nacionais de CO₂, é necessário que seja realizada a contabilização das emissões e remoções antrópicas de GEE (IPCC, 2006). O SEEG, por utilizar uma abordagem mais conservadora, opta por priorizar a divulgação dos dados com emissões brutas. As estimativas de emissões brutas de gases de efeito estufa não consideram as remoções de CO₂ pelas mudanças de uso do solo, por exemplo. Quando há desconto das remoções, as estimativas são dadas como emissões líquidas.

2.1.5 Processo de exploração de carvão mineral

A poluição atmosférica ligada às atividades de mineração se faz presente em todas as fases do empreendimento termelétrico. Sabe-se que a vida útil de uma mina em geral é de dezenas de anos e os problemas causados permanecem na região pelo mesmo tempo da mina e muitas vezes até por mais. O processo de mineração produz emissões de vários tipos de poluentes, com destaque para os óxidos de carbono, nitrogênio e enxofre (CHEN *et al.*, 2005). Essas emissões de gases de efeito estufa na mineração do carvão dependem de diversos fatores desde a geologia do depósito até a classificação do carvão, sendo a classificação mais alta geralmente a com maior teor de CH₄ (AYDIN *et al.*, 2012).

Há dois processos de exploração de carvão: a mineração a céu aberto e a mineração subterrânea (TIWARY, 2001). A mineração a céu aberto apresenta um método onde as camadas de solo superficiais, bem como formações sedimentares que cobrem o carvão, são removidas para que posteriormente seja realizado o processo de lavra do carvão, sendo este método de lavra geralmente pouco emissor de gás metano (UNECE, 2022). Já na mineração subterrânea, o carvão é explorado através do método câmara e pilares ou pelo método de lavra com caimento no teto. A exploração de carvão na jazida de Candiota, controlada pela Companhia Riograndense de Mineração (CRM), se dá através da mineração a céu aberto, pois esse é um método mais seguro para os trabalhadores e como as reservas são bastante superficiais, de até 50 metros de profundidade (CRM, 2021), a extração dessa forma é facilitada.

No processo de mineração de carvão a céu aberto, o processo é iniciado com a extração de toda a cobertura vegetal que cobre a jazida até que ela seja exposta. Somente após essa extração a mineração começa a acontecer de fato, bem como o transporte do carvão até o empreendimento. As atividades envolvidas neste processo seguem uma sequência: (1) perfuração e detonação da rocha e do carvão; (2) extração, carregamento e transporte de rochas e resíduos de carvão; (3) preparação do carvão; (4) carregamento, transporte e armazenamento do carvão; e (5) uso final do carvão em termelétricas para a geração de energia (ESPITIA-PÉREZ, 2016).

Durante a mineração do carvão, substâncias como material particulado, hidrocarbonetos e metais traços são liberados na atmosfera. Alguns compostos também são gerados e emitidos, como óxidos de enxofre, óxidos de nitrogênio e o monóxido de carbono, esse último gerado a partir da combustão espontânea do carvão na armazenagem e nos rejeitos (PEUKER e FAGUNDES, 2006).

As principais fontes de emissão de gases no processo de mineração são através do consumo de energia e de combustível utilizado no transporte do carvão, processos que correspondem a 90% dos gases oriundos dessa atividade (IBRAM, 2014). Em estudos recentes realizados na China (ZHANG *et al.*, 2022) identificou-se como fonte de emissão de metano, além de áreas de aterro sanitário e campos de arroz, áreas de mineração de carvão a céu aberto, relacionando os altos valores de CH₄ encontrados às emissões antrópicas por atividades energéticas que mantém as concentrações na área de estudo em níveis elevados. De acordo com a Environmental Protection Agency – US EPA (2012), a China é responsável por aproximadamente 50% do total de emissão global de metano, sendo considerada a maior emissora de CH₄ por mineração de carvão. Na Europa, a Bacia

de Carvão da Alta Silésia ao sul da Polônia, e na Rússia a região de Kemerovo (TRENCHÉV *et al.*, 2023), também são alvos de avaliação de emissão de metano, bem como outros gases causadores do efeito estufa, por serem as maiores áreas de mineração de carvão da Europa e da Rússia. A região carbonífera da Europa é um dos pontos de maior emissão desse gás na região (KRAUTWURST *et al.*, 2021), e diferentemente da área de mineração do estudo realizado na China, a lavra do carvão nesta bacia se dá de forma subterrânea. Globalmente, áreas de mineração de carvão são responsáveis por cerca de 350 Mt CH₄ ano⁻¹ (SAUNOIS *et al.*, 2020) e de acordo com Kholod *et al.* (2020) essas áreas são menos estudadas quando comparadas com os setores de gás e petróleo.

2.2 Metodologia

2.2.1 Localização e caracterização da área de estudo

A área de estudo (Figura 1) localiza-se na região sul do Estado do Rio Grande do Sul e abrange aproximadamente 935 km² que engloba totalmente o município de Candiota. A área é representada na Figura 1.

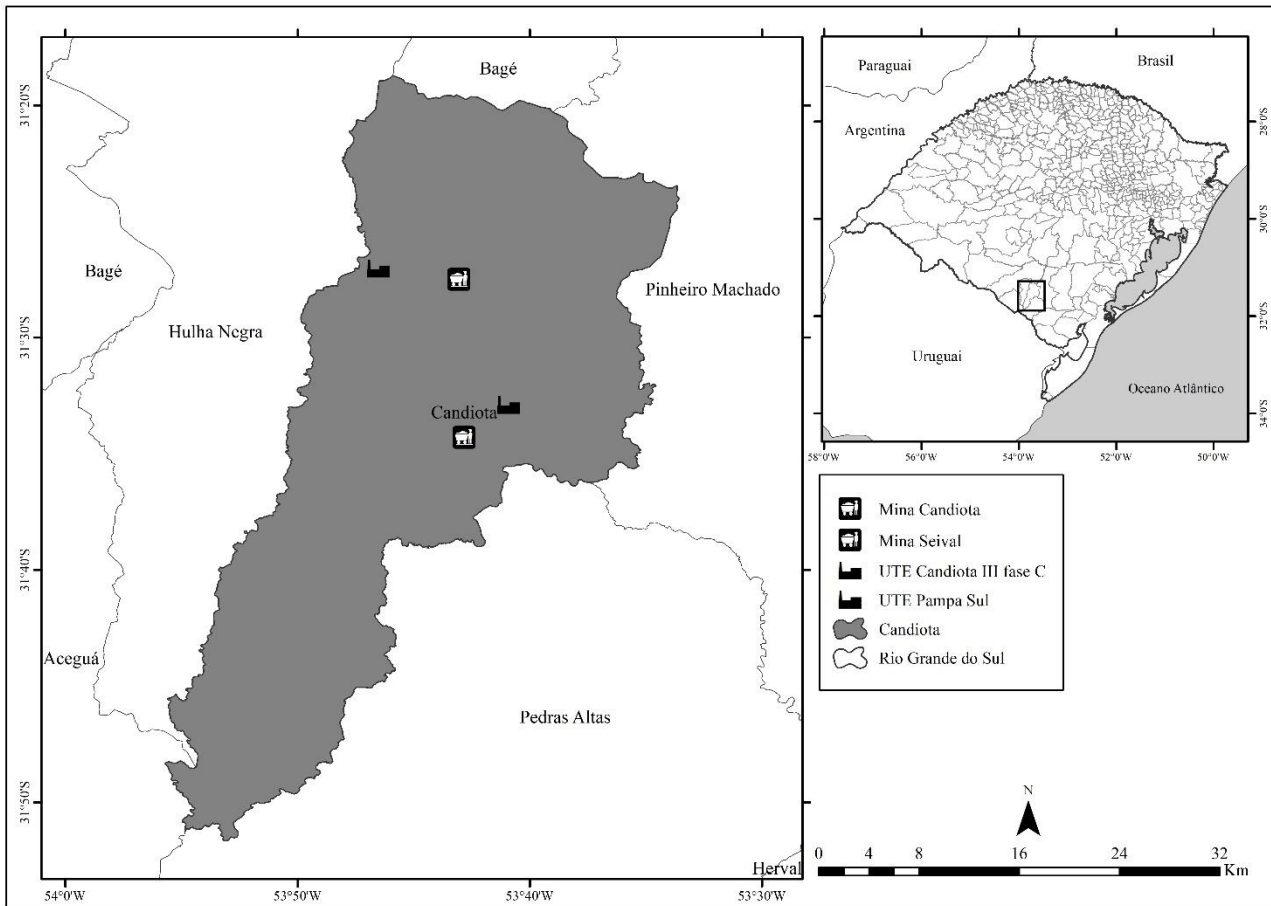


Figura 1 - Área de estudo com destaque para as Centrais Geradoras Termelétricas (UTES) e áreas de mineração consideradas no estudo.

Encontra-se em operação na região a Usina Termoelétrica Candiota III Fase C, de propriedade da Âmbar Energia. O complexo termoelétrico realiza a queima do carvão mineral oriundo da Mina de Candiota, operada pela Companhia Riograndense de Mineração (CRM). A Fase C possui potência de 350 MW (CGT ELETROSUL, 2024). Em relação ao monitoramento da qualidade do ar a empresa conta com três estações na região (Candiota, Aeroporto e Três Lagoas).

Outra usina que se encontra em operação na região é a Usina Termelétrica Pampa Sul, operada pela Starboard e Perfin, com 345 MW de potência instalada. Essa usina iniciou sua operação comercial em junho de 2019 e possui autorização de operação por 25 anos, a partir de janeiro de 2019 (PAMPA SUL, 2024). Está usina utiliza como combustível para a geração de energia o carvão mineral proveniente da Mina Seival, a qual é operada pela Seival Sul Mineração (SSM), empresa pertencente ao grupo Copelmi Mineração.

A área de estudo está inserida no bioma Pampa, Ecorregião Campos Sulinos, e abrange formações florestais e campestres. Dentre essas, foram identificadas, conforme a

classificação apresentada no Manual Técnico da Vegetação Brasileira (IBGE, 2012), as seguintes formações: Estepe; Savana-Estépica; Floresta Estacional; e Áreas das Formações Pioneiras Vegetação com Influência Fluvial e/ou Lacustre. A região em torno dos empreendimentos termelétricos é coberta predominantemente por vegetação nativa, cerca de 65% do total. O restante corresponde a áreas antropizadas. Contudo, cabe destacar que parte expressiva desta vegetação nativa está alterada, visto que há tempos a vegetação campestre da região se transformou em áreas de pasto natural.

O clima da região, segundo Alvares *et al.* (2013), é do tipo Cfa: subtropical (Zona C), úmido (f) e com verão quente (a), de acordo com os critérios da classificação climática de Köppen (1936). Neste, a letra “f” indica precipitação pluvial mensal bem distribuída ao longo do ano; e a letra “a” se refere à temperatura média do mês mais quente ser maior ou igual a 22 °C e a temperatura média do mês mais frio estar entre -3 e 18 °C.

2.2.2 Mapeamento da área a partir de Análise de Imagens Baseada em Objetos Geográficos

Foi utilizado o método de classificação a partir de Análise de Imagens Baseada em Objetos Geográficos (*Geographic Object-Based Image Analysis - GEOBIA*), utilizando o algoritmo de classificação *Random Forest* (RF) para a identificação e classificação dos padrões e características da composição e uso do solo na região de interesse. Nesse método, a unidade de processamento são grupos de pixels, denominados de regiões, que posteriormente serão classificados pelo algoritmo.

Para a classificação foram utilizadas imagens orbitais do satélite Sentinel-2A, nas 13 bandas do sensor MSI (*Multispectral Instrument*). A qualidade das classificações dos resultados obtidos foi avaliada por meio da Acurácia Geral e Índice Kappa, obtidos através da Matriz Confusão.

Por meio do Índice Kappa é possível classificar o nível de precisão do método utilizado, conforme Tabela 2.

Tabela 2 - Intervalo de aceitação dos resultados do Índice Kappa (LANDIS e KOCH, 1977).

Índice Kappa (K)	Característica
$K \leq 0,2$	Ruim
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Bom
$0,6 < K \leq 0,8$	Muito bom

2.2.3 Experimento de campo

A escolha do local das coletas de material vegetal, solo e gases, foi definida em função da acessibilidade, da disponibilidade de infraestrutura e transporte, da direção predominante do vento e da proximidade com os empreendimentos termelétricos e de mineração, além de contemplar toda a extensão da área de estudo. Foram selecionadas três áreas amostrais: Ponto 1 (Fazenda Copelmi) - oposto ao vento predominante; Ponto 2 (Mina - CRM) - mina de carvão; e Ponto 3 (Sítio – UTE) - próximo à usina, na direção do vento predominante (Figura 2). Nos pontos amostrais a composição vegetal é descrita por espécies de gramíneas: Ponto 1, com maior dominância de *Lolium Multiflorum* Lam. (azevém-italiano) e *Lolium Perene* (azevém-perene) (Figura 2a).; Ponto 2, com maior dominância de *Urochloa Decumbens* (capim-braquiária) (Figura 2b).; e Ponto 3, com maior dominância de *Andropogon Lateralis* (capim caninha) (Figura 2c).

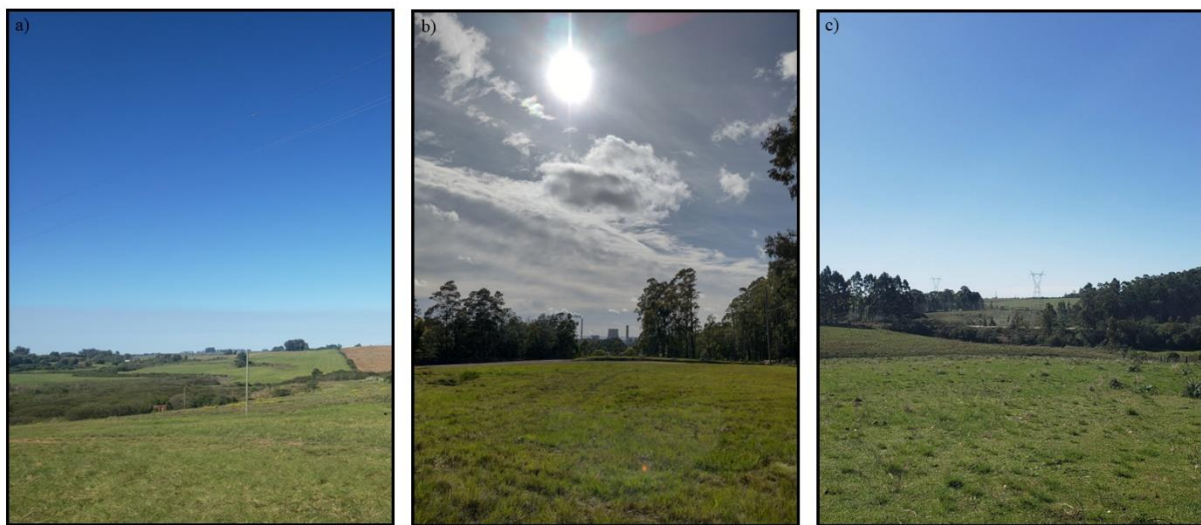


Figura 2 - Composição vegetal dos pontos amostrais (a) Ponto 1 (Fazenda Copelmi), (b) Ponto 2 (Mina - CRM) e (c) Ponto 3 (Sítio – UTE).

Para coleta das amostras de tecido vegetal foi empregado o método área fixa (SANQUETTA *et al.*, 2014) e definidas quatro parcelas em cada área, com 25 m de comprimento e 10 m de largura, totalizando 12 parcelas. A coleta de vegetação foi feita aleatoriamente em cada parcela de campo selecionada posicionadas com o uso de GPS, de acordo com a metodologia proposta por (SALMAN *et al.*, 2006), onde a partir do “método do quadrado”, utilizando um quadro de madeira de 50 x 50 cm (0,25 m²), o material vegetal foi cortado rente ao solo.

O material vegetal então foi armazenado e pesado, para obtenção da biomassa verde, e posteriormente encaminhado a estufas para obtenção da biomassa seca. O material foi seco a uma temperatura de 40° até atingir peso constante, e quantificado em relação a sua massa. As amostras de biomassa seca foram então moídas e analisadas quanto aos teores de carbono por combustão seca em analisador CN (Flash 2000 IRMS, Thermo Fisher Scientific). As coletas foram realizadas nas estações de primavera e inverno, respectivamente em 14 de outubro de 2022 e 28 de julho de 2023. Os processos que compõem esta etapa da pesquisa são apresentados na Figura 3.



Figura 3 - Metodologia aplicada para posterior obtenção de biomassa e carbono dos pontos amostrais. (1) coleta da vegetação por meio do método do quadrado; (2) pesagem da vegetação antes e após secagem em estufa; (3) moagem das amostras em moinho e posterior em cilindro, (4) preparo das amostras para envio laboratorial.

Os fluxos de CO₂ e CH₄ do solo para a atmosfera foram acompanhados durante as duas campanhas de amostragem, nas estações de primavera e inverno, utilizando a técnica de câmaras estáticas (fechadas) (Figura 4). Para a medição dos gases, utilizaram-se câmaras cilíndricas de PVC (25 cm de diâmetro x 20 cm de altura) instaladas nas parcelas selecionadas, em cada parcela foram posicionadas quatro câmaras estáticas no solo a uma profundidade de 5 cm. As coletas se deram no período da manhã (9h-11h) para minimizar a variação diurna da temperatura e umidade do ar.

Posteriormente as câmaras foram fechadas com tampa de PVC com septo na parte superior, que restringe os fluxos de ar do solo para a atmosfera. As amostras de gases então retiradas da câmara em intervalos de 0, 15, 30 e 45 minutos após o fechamento das câmaras, com seringas de 20 mL equipadas com válvulas de três vias, após transferidos para frascos evacuados para transporte e armazenamento até serem encaminhadas a laboratório para análise de CO₂ e CH₄. A temperatura do solo (TS, °C) e a umidade do solo (URS, %, m³ m⁻³) na camada de solo se 0-5 cm também foram medidas em cada tempo de amostragem do gás.

As concentrações de CO₂ e CH₄ foram determinadas por cromatografia gasosa em equipamento GC Trace 1310 (Thermo Scientific), equipado com detector de captura eletrônica para CO₂ e detector de ionização de chama para CH₄. Como controle de qualidade da análise de GC, foi utilizada uma curva padrão de concentração de gás, com quatro concentrações padrão de CO₂ e CH₄ (misturas padrão fornecidas pela Praxair-White Martins), e para cada 20 amostras, uma amostra padrão também foi analisada para verificar a precisão das medições. Os processos que compõem esta etapa da pesquisa são apresentados na Figura 4.



Figura 4 – Metodologia aplicada para obtenção dos fluxos de CO₂ e CH₄ no solo, (1) base metálica preenchida com água; (2) câmara instalada para coleta das amostras de gás; (3) coleta das amostras; (4) transferência das amostras coletadas em campo para os *vials* e armazenamento até serem enviadas ao laboratório para análise.

As amostras compostas de solo foram coletadas no dia 14 de outubro de 2022, em condição de campo nativo e pastagem plantada no Ponto 1 (Fazenda Copelmi); Ponto 2 (Mina - CRM); e no Ponto 3 (Sítio – UTE), nas camadas de 0-10 cm (superfície) e 10-20 cm (subsuperfície) de profundidade, posteriormente mantidas em refrigeração a aproximadamente 4 °C. Nas três unidades amostrais definidas (50 x 20 m) a área foi percorrida em “zig-zag” para que fossem coletadas cerca de 15 subamostras. Após, as subamostras foram homogeneizadas, seguindo a metodologia proposta pela EMBRAPA SOLOS (1997). O material foi armazenado em sacos plásticos até o momento da secagem ao ar em estufa a 40 °C, até peso constante, destorroado, passado em peneira com malha de 2 mm para obtenção da fração terra fina seca ao ar e moído em gral de ágata, de acordo com Fruett *et al.* (2022). Cerca de 50 mg de cada amostra foram submetidos à combustão seca em analisador de carbono (Flash 2000 IRMS, Thermo Fisher Scientific) para determinação do carbono orgânico total (COT). Os processos que compõem esta etapa da pesquisa são apresentados na Figura 5.



Figura 5 – Metodologia aplicada para obtenção do carbono orgânico total do solo nos três pontos amostrais. (1) coleta das amostras de solo com uso de trado holandês; (2) preparo das amostras para secagem em estufa; (3) passagem das amostras secas em peneira e moídas em gral de ágata; (4) preparo das amostras para envio ao laboratório.

2.2.4 Estimativa do estoque de Carbono em superfície

Um importante gás de efeito estufa presente na atmosfera e que desempenha um importante papel nas mudanças climáticas é o CH₄, que pode ser estimado em escala local e global com resolução espacial relativamente alta.

O produto XCH₄ utilizado neste estudo foi o fornecido pelo TROPOMI (*TROPospheric Monitoring Instrument*), sensor multiespectral a bordo do satélite Sentinel-5P (*Sentinel-5 Precursor*) (Apituley et al., 2021), que possui resolução espacial de 7 km e período de revisita de 17 dias. Foram adquiridos dados de 2019 a 2022, por meio da plataforma *Google Earth Engine*, cuja data mais antiga disponível para XCH₄ é fevereiro de 2019. Os dados foram filtrados com condição de confiabilidade maior que 0,5. Posteriormente os mapas de concentração espacial de CH₄ foram realizados no software ArcMap (ArcGIS).

Para a correlação com os dados biofísicos e a geração das equações de regressão foram utilizados dados ópticos provenientes de séries temporais do Sentinel 2. A correlação estatística foi estabelecida entre as bandas espectrais, *Red* (B4) e *Red Edge 1* (B5), e os índices de vegetação, NDVI (*Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*), sPRI (*Photochemical Reflectance Index* - reescalado para valores positivos), CO₂flux (integração do sPRI com o NDVI (BAPTISTA, 2003)) e CO₂flux_NDRE (calculado a partir do índice NDRE), com os valores das variáveis biofísicas coletadas em campo. Foram analisados os dados de peso de biomassa fresca, biomassa seca, e carbono orgânico obtidos em laboratório em relação aos índices de vegetação aplicados sobre as imagens do sensor Sentinel-2, no mesmo período ou próximo.

Os valores da resposta espectral para cada índice de vegetação foram obtidos através da média dos *pixels* correspondentes as amostras obtidas em cada uma das unidades amostrais. A estimativa de biomassa e carbono orgânico a partir dos dados espectrais foi realizada através de análises de correlação entre os dados coletados em campo e analisados em laboratório e a resposta espectral dos índices de vegetação. Posteriormente, foi feita uma análise de regressão linear gerando um modelo estatístico empírico, tendo como variável dependente a biomassa e o carbono da vegetação quantificada em cada unidade amostral e como variável independente os valores dos índices de vegetação.

Realizaram-se testes estatísticos para selecionar os índices com contribuição mais significativa para compor os modelos de regressão, bem como testes (*Mean Absolut Error* - MAE; *Mean Squared Error* - MSE; *Coefficient of Determination* – R²) para validação das

regressões e análise de erros. Pretendendo-se com estes modelos, inferir sobre a biomassa e estoques de carbono da vegetação.

2.3 Resultados e discussões

A produção científica decorrente da tese foi realizada em formato de artigos científicos conforme normas do Programa de Pós-Graduação em Sensoriamento Remoto, listados a seguir:

- **Artigo 1:** PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto em área sob influência de empreendimentos termelétricos e mineração.
<https://doi.org/10.26848/rbgf.v17.2.p1362-1374>
- **Artigo 2:** PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D.; FONTANA, D. C.; MORAES, O. L. L. Assessment of the relationship between biomass and carbon near coal mining and combustion areas.
- **Artigo 3:** PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D.; BAYER, C.; CAUMO, M. CO₂ and CH₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining.

2.3.1 *Artigo 1: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto em área sob influência de empreendimentos termelétricos e mineração.*

<https://doi.org/10.26848/rbgf.v17.2.p1362-1374>



Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto em área sob influência de empreendimentos termelétricos e mineração

Bruna Lüdtke Paim¹, Rita de Cássia Marques Alves², Bianca Dutra de Lima³

¹ Me. em Meteorologia Aplicada, Doutoranda, Programa de Pós-graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 9500, Prédio 44202, Bairro Agronomia, CEP 91501-970, Porto Alegre, Rio Grande do Sul. (51) 3308-6966. bruhpaim20@gmail.com (autor correspondente). ² Professor Dr. Titular, Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 9500, Bairro Agronomia, CEP 91501-970, Porto Alegre, Rio Grande do Sul. rita.cma@terra.com.br. ³ Me. em Sensoriamento Remoto, Doutoranda, Programa de Pós-graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 9500, Prédio 44202, Bairro Agronomia, CEP 91501-970, Porto Alegre, Rio Grande do Sul. (51) 3308-6966. bianca_duli@hotmail.com.

Artigo recebido 07/11/2023 em e aceito em 06/03/2024

RESUMO

O uso de técnicas utilizando imagens e dados de sensoriamento remoto para a obtenção de índices de vegetação já é amplamente difundido para aplicações em ecossistemas vegetais, o que auxilia na tomada de decisões. Da mesma forma, o emprego de classificadores de cobertura do uso do solo também está se tornando popular em meio a pesquisas na área de análise de dados ambientais, pois possibilita a identificação espacial de diversos tipos de coberturas de solo, incluindo infraestrutura urbanas e mineração, que posteriormente podem ser relacionadas com emissões de gases na atmosfera. O objetivo deste trabalho foi analisar os padrões de cobertura do solo obtidos por meio do NDVI, e realizar a classificação supervisionada em áreas impactadas por empreendimento termelétricos e mineração, relacionando-as com as emissões de gases de efeito estufa a partir de dados de sensoriamento remoto. O estudo analisou a aplicação do algoritmo de classificação supervisionada *Random Forest*, o qual apresentou excelentes resultados estatísticos, com índice Kappa de 0,83. O mapeamento das classes de uso do solo obtido permitiu uma avaliação em termos de ocupação e uso na área de estudo, dados posteriormente comparados com o comportamento do CO₂Flux, bem como com as emissões de metano estimadas pelo sensor TROPOMI. Os resultados apontaram relação entre a distribuição de biomassa e carbono com a distribuição de atividades agrícolas e de energia, sendo estas as duas regiões que apresentam valores mais elevados de metano. Em contrapartida, os valores de CO₂Flux foram maiores em áreas classificadas como Floresta e Vegetação campestre.

Palavras-chave: sensoriamento remoto, classificação supervisionada, carbono, mineração.

Estimating biomass and carbon using remote sensing techniques in an area under the influence of thermoelectric and mining projects

ABSTRACT

The use of techniques using remote sensing images and data to obtain vegetation indices is already widespread for applications in plant ecosystems, which helps in decision-making. Similarly, the use of land use cover classifiers is also becoming popular in environmental data analysis research, as it provides spatial identification of different types of land cover, including urban infrastructure and mining, which can later be related to gas emissions into the atmosphere. The aim of this work was to analyze the land cover patterns obtained using NDVI, and to perform supervised classification in areas impacted by thermal power plants and mining, relating them to greenhouse gas emissions using remote sensing data. The study analyzed the application of the *Random Forest* supervised classification algorithm, which showed excellent statistical results, with a Kappa index of 0.83. The mapping of land use classes obtained allowed an assessment to be made in terms of occupation and use in the study area, data which was then compared with the behavior of CO₂Flux, as well as with methane emissions estimated by the TROPOMI. The results revealed a relationship between the distribution of biomass and carbon and the distribution of agricultural and energy activities, these being the two areas with the highest methane values. On the other hand, CO₂Flux values were higher in areas classified as forest and grassland vegetation.

Keywords: remote sensing, supervised classification, carbon, mining.

Introdução

O desenvolvimento de técnicas de geoprocessamento, incluindo o sensoriamento remoto, é uma importante ferramenta no planejamento ambiental, pois possibilita que fenômenos e características do ambiente como uso e cobertura do solo sejam representados de forma ampla, tanto espacial quanto temporal (Beamish et al., 2020). O sensoriamento remoto fornece dados espaciais e temporais para monitoramento da superfície terrestre que permitem a geração de índices de vegetação associados à produção e estoque de biomassa vegetal e porcentagem de uso e cobertura do solo.

Dentre os diversos índices de vegetação existentes, o Índice de Vegetação de Diferença Normalizada (NDVI), amplamente utilizado na literatura, é um bom preditor de biomassa verde, tanto úmida quanto seca e expressa de forma eficiente o estado e os atributos da vegetação (Huang et al., 2020). Para a estimativa de biomassa é necessário também a utilização de índices sensíveis a senescência foliar, como é o caso do Índice de Reflectância Fotoquímica (PRI), desenvolvido para observação das condições fisiológicas da vegetação (Ryu et al., 2021). O uso combinado desses dois índices gera informações úteis em um sistema de monitoramento de vegetação, biomassa e cobertura do solo.

A classificação do uso e da cobertura do solo através do emprego de índices de vegetação é realizado a partir da identificação dos padrões de energia eletromagnética refletida pela superfície terrestre convertida em classes. Essa classificação pode ser supervisionada ou não supervisionada, sendo esta primeira amplamente utilizada para análise de dados e imagens, sendo aplicada em inúmeros trabalhos com o objetivo de estudar tipos diferentes de cobertura de solo (Santos et al., 2019; Bizon et al., 2020; Carvalho et al., 2021; Hamud et al., 2021). Nos últimos anos diversos algoritmos de classificação supervisionada foram desenvolvidos, dentre eles estão o *K-nearest neighbor* (KNN), *Support Vector Machine* (SVM), *Classification and Regression Tree* (CART) e o *Random Forest* (RF), que têm sido usados para mapeamento de paisagens em diferentes ambientes, desde áreas costeiras (Zhang et al., 2020) até regiões de dunas na América do Sul (Currihuinca et al., 2021) e de trunda no Círculo Polar Ártico (Liu et al., 2023), além do mapeamento de culturas e espécies (Lima et al., 2023). Dentre esses algoritmos, o RF tem apresentado melhor acurácia quando comparado aos demais. Em sua pesquisa de avaliação de algoritmos de classificação supervisionada, Wang et al. (2019) obtiveram valor de acurácia de

aproximadamente 91%, superior aos demais algoritmos testados (KNN e SVM). Já Lou et al. (2020) aplicando métodos de classificação de imagens na China, obtiveram mais de 70% de precisão geral para todos os cenários aplicados no estudo, utilizando imagens de diferentes sensores, com uso do algoritmo RF. Similarmente, Bizon et al. (2020) ao mapearem a região sul do Brasil, mais precisamente o estado de Santa Catarina, também concluíram que o classificador possui um alto desempenho na classificação de imagens. Considerando a sua boa acurácia, a partir deste método é possível identificar espacialmente os tipos de cobertura do solo em uma dada região, como por exemplo, áreas de vegetação, agricultura, infraestrutura urbana e mineração, que posteriormente podem ser relacionadas com emissões de gases na atmosfera.

O processo de mineração produz a emissão de vários tipos de poluentes na atmosfera dentre os quais destacam-se os óxidos de carbono. De acordo com Saunio et al. (2020), a mineração do carvão é responsável por aproximadamente um décimo do total das emissões antropogênicas de metano (CH₄) no mundo, que é gerado a partir da combustão espontânea do carvão no armazenamento e nos rejeitos (Peuker e Fagundes, 2006). As emissões de metano provenientes da mineração são influenciadas por diversos fatores, como, geologia do local de extração, método de extração e a classificação do carvão, a qual quanto mais alta, maior o teor de metano (Trenchev et al., 2023).

Também por meio de técnicas que utilizam sensoriamento remoto, é possível compreender a distribuição, tanto espacial quanto temporal das concentrações atmosféricas desse poluente. Para tal, pesquisadores utilizam dados fornecidos por diferentes sensores e plataformas para estudar as variações espaço-temporais do metano na atmosfera, como por exemplo dados do Sentinel-5P (Kozicka et al., 2021; Zhang et al., 2022) e os obtidos pela sonda Atmospheric Infrared Sounder (AIRS) a bordo do satélite Aqua (Wu et al., 2019). De acordo com Ni et al. (2023) a principal diferença entre esses dois produtos está no comprimento de onda do espectro eletromagnético, enquanto o TROPOMI utiliza espectro do infravermelho de onda curta, mais sensível perto da superfície o AIRS utiliza espectro do infravermelho termal, apresentando boa sensibilidade na troposfera média-alta.

Entender como as principais fontes e sumidouros de CO₂ e CH₄ se comportam é fundamental para a implementação de projetos que visam mitigar os efeitos desses gases frente ao aquecimento global e as mudanças climáticas visto

que o Brasil, e em destaque o estado do Rio Grande do Sul, estabeleceram sua meta de neutralidade de carbono em 2021, esperando reduzir pela metade as emissões de gases de efeito estufa até 2030 e atingir zero emissões líquidas de carbono até 2050 (RS, 2021).

Neste contexto, o objetivo deste trabalho foi analisar os padrões de cobertura do solo obtidos por meio do NDVI, sensível a biomassa de vegetação, e realizar a classificação supervisionada em áreas impactadas por empreendimentos termelétricos e mineração a céu aberto,

relacionando-as com as emissões de gases de efeito estufa a partir de dados de sensoriamento remoto.

Material e métodos

Área de Estudo

A área de estudo concentra-se em Candiota, na região sul do estado do Rio Grande do Sul, e abrange 935 km². O local está inserido no bioma Pampa, Ecorregião Campos Sulinos, e abrange formações florestais e campestres. Cabe destacar que parte expressiva desta vegetação nativa está alterada, visto que há tempos a vegetação campestre foi transformada em área de pastagem.

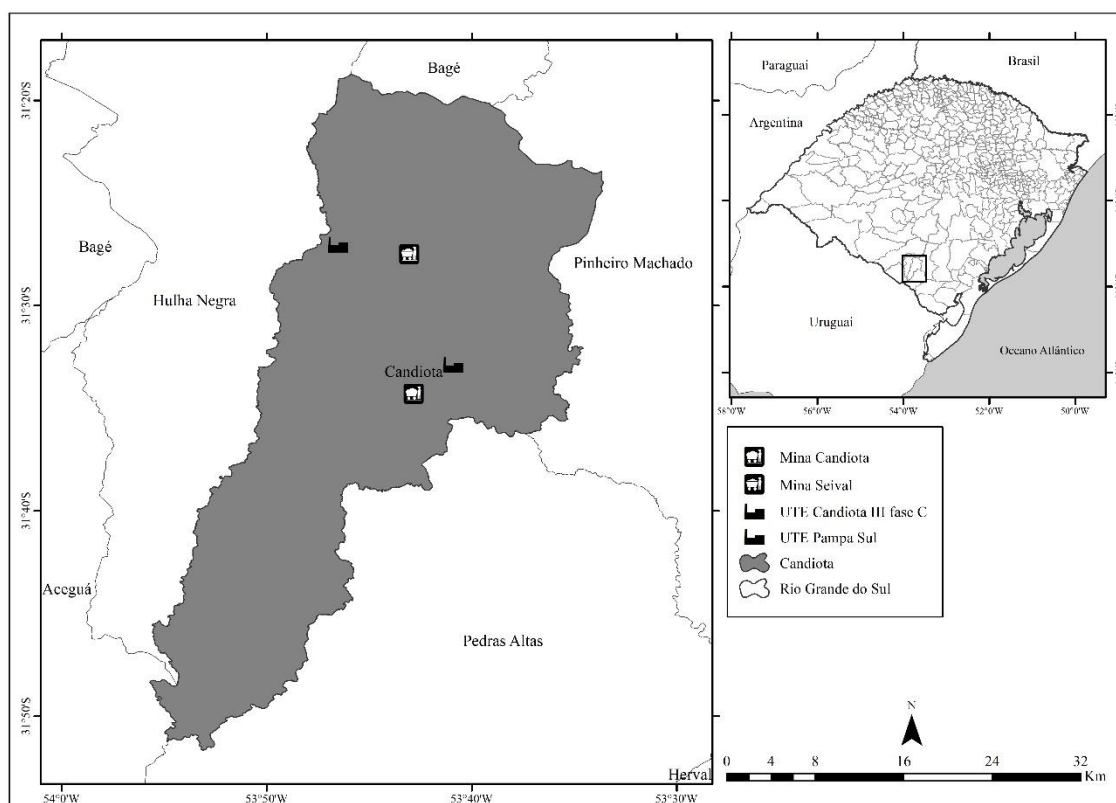


Figura 1. Área de estudo com destaque para as UTEs e áreas de mineração consideradas no estudo.

O clima da região, segundo Alvares et al. (2013), é do tipo Cfa: subtropical (Zona C), úmido (f) e com verão quente (a), de acordo com os critérios da classificação climática de Köppen (1936). Neste, a letra “f” indica precipitação pluvial mensal bem distribuída ao longo do ano; e a letra “a” refere-se à temperatura média do mês mais quente ser maior ou igual a 22 °C e a temperatura média do mês mais frio estar entre -3 e 18 °C.

Mapeamento da área a partir de Análise de Imagens Baseada em Objetos Geográficos

O método escolhido para a classificação foi o de Análise de Imagens Baseada em Objetos

Geográficos (*Geographic Object-Based Image Analysis - GEOBIA*), utilizando o algoritmo de classificação *Random Forest* (RF) para a identificação e classificação dos padrões e características da composição e uso do solo na região de interesse. Nessa metodologia, a unidade de processamento são grupos de pixels, denominados de regiões, que posteriormente são classificados pelo algoritmo.

Utilizou-se imagens orbitais do satélite Sentinel-2A (dado de maior resolução espacial disponível para a área de estudo), nas 13 bandas do sensor MSI (correção atmosférica aplicada a produtos de ortoimagem Nível-1C). Aplicou-se um

filtro de nuvens de >10%, disponibilizando um total de 405 imagens entre os anos de 2019 e 2022. Realizou-se o recorte da área de estudo com a importação da delimitação gerada em formato vetorial *shapefile*. A seguir, para a classificação supervisionada, foi usada a técnica de segmentação, onde as imagens foram segmentadas em regiões espectralmente diferentes com o uso do algoritmo SNIC (*Simple Non-Iterative Clustering*), modo de segmentação baseado em clusters amplamente utilizado devido as melhorias em eficiência computacional, consumo de memória e qualidade quando comparado ao seu antecessor, SLIC (*Simple Linear Iterative Clustering*) (Achanta et al. 2017). Os parâmetros utilizados na aplicação do algoritmo de segmentação foram: *seeds* (grade regular de sementes), *size* (5), *compactness* (0), *connectivity* (2) e *neighborhoodSize* (0).

Coletou-se segmentos que representassem cada classe de uso e cobertura do solo. As seis classes estipuladas foram: Água, Floresta, Vegetação campestre, Agricultura, Infraestrutura urbana e Mineração. A determinação das classes de uso e cobertura do solo foi baseada na classificação de Weber (2018) para uso e cobertura vegetal do

estado do Rio Grande do Sul em 2015, e confirmada através de análise exploratória realizada com o auxílio das imagens de alta resolução disponíveis no *Google Earth*. Na classe Água reuniu-se os rios, lagos, pequenos açudes e córregos. A classe Floresta foi composta por formações florestais nativas e plantadas; a classe Vegetação campestre por pastagens naturais que ainda não foram substituídas por outros usos e pastagem plantada. A classe Agricultura reuniu áreas de plantio para produção agrícola, principalmente cultivos de arroz e soja, enquanto a classe Infraestrutura urbana compreendeu o sistema rodoviário pavimentado e as áreas correspondentes à cidade de Candiota, como vilas, bairros e áreas urbanas isoladas. Por fim, a classe Mineração correspondeu às áreas de exploração de atividade mineral nas Minas Candiota e Seival, locais esses que possuem predomínio não agrícola (IBGE, 2012) (Tabela 1). Neste mapeamento, visando um melhor resultado, foram coletados 2588 pontos, sendo 70% desses pontos utilizados para calibração e 30% para validação da classificação RF, sendo essa porcentagem tomada como verdade terrestre.

Tabela 1. Classe de uso e cobertura do solo na área de estudo.

Classe	Descrição
Água	Rios, lagos e córregos
Floresta	Formação florestal
Vegetação campestre	Pastagem natural e plantada
Agricultura	Arroz e soja
Infraestrutura urbana	Áreas urbanas e rodovias pavimentadas
Mineração	Mina Candiota e Mina Seival

Os dados de entrada para o classificador RF foram: amostras de treinamento; bandas B2 (496,6 nm – 492,1 nm), B3 (560 nm – 559 nm), B4 (664,5 nm – 665 nm), B5 (703,9 nm – 703,8 nm), B6 (740,2 nm – 739,1 nm), B7 (782,5 nm – 779,7 nm), B8 (835,1 nm – 833 nm), B8A (864,8 nm – 864 nm), B9 (945 nm – 943,2 nm), B11 (1613,7 nm – 1610,4 nm) e B12 (2202,4 nm – 2185,7 nm) do Sentinel-2A e o NDVI, amplamente utilizado já

que produz uma melhora significativa na precisão da classificação (Singh et al., 2016); e a imagem de segmentação. A avaliação da qualidade dos resultados obtidos foi realizada por meio da Acurácia Geral e do Índice Kappa (Landis e Koch, 1977), este último que quantifica o nível de precisão do método conforme (Tabela 2), ambos obtidos através da Matriz de Confusão.

Tabela 2. Intervalo de aceitação dos resultados do Índice Kappa.

Índice Kappa	Característica
$K \leq 0,2$	Ruim
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Bom
$0,6 < K \leq 0,8$	Muito Bom
$K > 0,8$	Excelente

Estimativa de biomassa e carbono a partir de técnicas de sensoriamento remoto

Foram utilizadas imagens orbitais do satélite Sentinel-2A pré-processadas da mesma forma que as utilizadas para a classificação supervisionada.

A refletância fotoquímica da vegetação foi estimada com base no Índice de Refletância Fotoquímica (PRI - *Photochemical Reflectance Index*), sensível às mudanças nos pigmentos carotenoides na folhagem, o que serve como indicativo da eficiência do uso da luz fotossintética ou da taxa de dióxido de carbono armazenada pela folhagem por unidade de energia absorvida. Em geral este índice é utilizado para estudos de estresse e produtividade da vegetação e tem seus valores variando de -1 a 1 (Gamon et al., 1992; Canavesi et al., 2010). O PRI é resultado da relação entre as bandas espectrais do verde e azul (Equação 1).

$$PRI = \frac{\rho G - \rho B}{\rho G + \rho B} \quad (1)$$

Onde, ρG é a refletância da banda espectral do verde; ρB é a refletância da banda espectral do azul.

Os valores do índice PRI foram reescalados para valores positivos, gerando o novo índice sPRI (Equação 2).

$$sPRI = \frac{PRI + 1}{2} \quad (2)$$

O índice CO_2flux é então calculado para estimar o fluxo de dióxido de carbono a partir da multiplicação do sPRI com o NDVI (Baptista, 2003) (Equação 3).

$$CO_2flux = NDVI * sPRI \quad (3)$$

Este método é amplamente utilizado para estimativas de CO_2 por sensoriamento remoto, porém há outro importante gás de efeito estufa presente na atmosfera e que desempenha um importante papel nas mudanças climáticas: o CH_4 , que pode ser estimado em escala local e global com resolução espacial relativamente alta.

O produto XCH_4 utilizado neste estudo foi o fornecido pelo TROPOMI (*TROPospheric Monitoring Instrument*), sensor multiespectral a bordo do satélite Sentinel-5P (*Sentinel-5 Precursor*) (Apituley et al., 2021), que possui resolução espacial de 7 km e período de revisita de 17 dias. Foram adquiridos dados de 2019 a 2022, por meio da plataforma *Google Earth Engine*, cuja data mais antiga disponível para XCH_4 é fevereiro de 2019. O período de verão foi definido entre os meses de dezembro a fevereiro, outono entre os meses de março a maio, inverno entre junho e agosto e a primavera entre setembro e novembro. Os dados foram filtrados com condição de confiabilidade maior que 0,5.

Resultados e discussão

Mapeamento da área a partir de GEOBIA

O mapa temático com os resultados da aplicação do método GEOBIA é apresentado na Figura 2. As áreas em azul representam a classe Água, em verde escuro a classe Floresta, em verde claro a classe Vegetação campestre, em laranja a classe Agricultura, em vermelho a classe Infraestrutura urbana e em cinza as áreas que correspondem a classe Mineração.

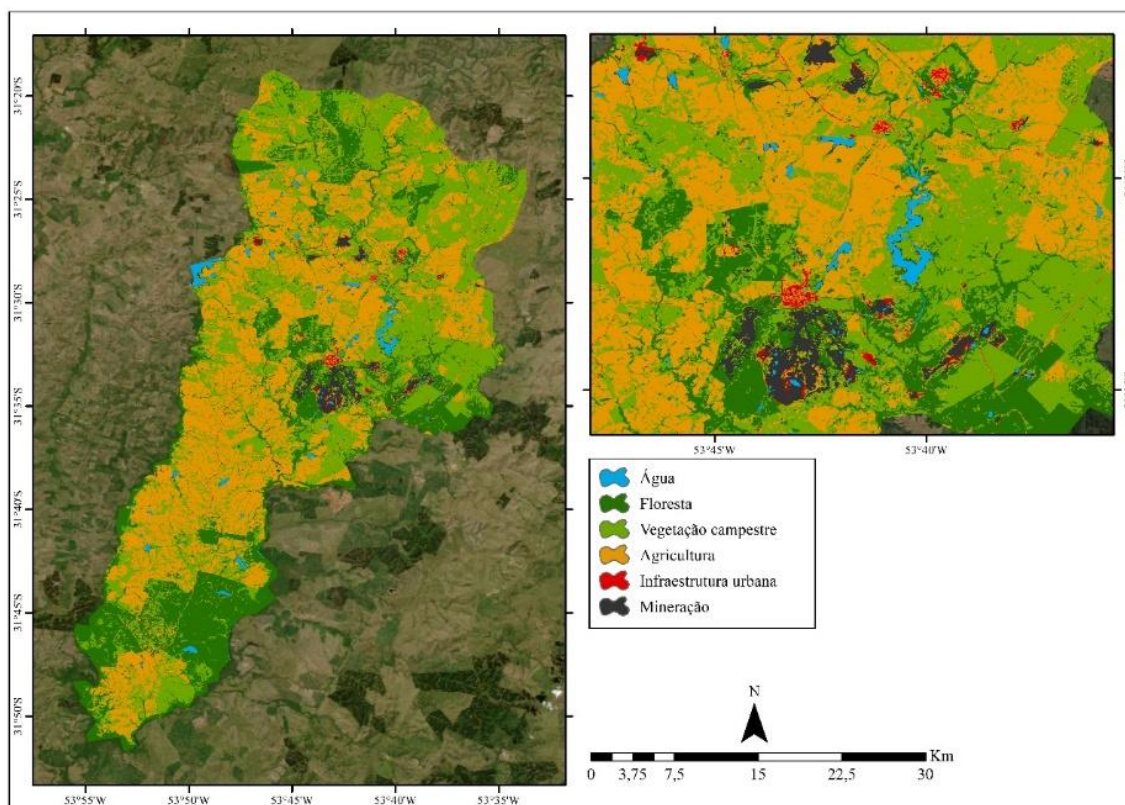


Figura 2. Classificação realizada pelo método *Random Forest*.

A Tabela 3 apresenta os resultados obtidos através da aplicação dos cálculos do coeficiente Kappa e Acurácia global utilizados para avaliar a exatidão da classificação mapeada.

O resultado da avaliação da acurácia da classificação em imagens de média resolução espacial teve resultado excelente segundo a Tabela 2 de concordância de Landis e Koch (1977) visto que o resultado foi superior a 0,8, o que representa um mapeamento bastante fiel e condizente com a

realidade. De acordo com Carvalho (2021), o método *Random Forest* é um algoritmo amplamente utilizado para classificação da cobertura do solo. Em seu trabalho de avaliação de algoritmos de classificação supervisionada utilizando o *Google Earth Engine*, os autores obtiveram valor de 0,9910, também classificado como excelente.

Tabela 3. Valores estatísticos de Acurácia Global e Coeficiente Kappa.

Estatística

Acurácia Global	0,9831
Índice Kappa	0,8267

A Acurácia do produtor tem como objetivo medir o quanto uma determinada área foi classificada corretamente pelo pesquisador, enquanto a Acurácia do usuário avalia a confiabilidade do mapa, medindo o quanto ele

representa a verdade terrestre (Banko, 1998). Os resultados percentuais para estes dois fatores são apresentados na Tabela 4.

Tabela 4. Valores de Acurácia do Produtor e Acurácia do usuário para cada classe de uso e cobertura do solo.

Classes	Acurácia do Produtor (%)	Acurácia do Usuário (%)
Água	100	100

Floresta	100	100
Vegetação campestre	96	97
Agricultura	97	96
Infraestrutura urbana	83	100
Área de mineração	100	96

É possível notar que as classes Água e Floresta apresentaram maiores precisões na classificação em ambos os fatores de Acurácia avaliados, resultados esses obtidos devido a homogeneidade presente nas duas classes, o que facilita a identificação dos alvos. A classe Vegetação campestre apresentou precisão superior a 90%.

A classe Infraestrutura urbana apresentou o menor percentual de acurácia do produtor, 83%. Isso pode estar relacionado à resolução espacial de 20 metros do Satélite Sentinel-2A, além da semelhança das respostas espectrais dos alvos presentes na superfície terrestre e/ou ainda pelo fato das áreas de mineração estarem localizadas próximas aos limites rurais-urbanos, o que contribui para que haja uma mistura no processamento das classes. Mesmo assim, devido aos percentuais obtidos nas demais classes mapeadas, identifica-se uma alta eficiência de classificação pelo método GEOBIA, sendo evidente a precisão obtida nas classificações das classes Água, Floresta, Vegetação campestre e Agricultura.

A partir das classes avaliadas também foram obtidas as porcentagens de cobertura de solo por cada uma, bem como a área em km² (Tabela 5). Os resultados obtidos a partir da aplicação do classificador mostram que na área de estudo a predominância da classe Agricultura (40,3%) é maior o que as áreas de Vegetação campestre (30,9%) que representam o bioma natural da região. Além disso, a Agricultura cobre também maior área do que a principal fonte de renda do município de Candiota que são as áreas de mineração (1,3%) e empreendimentos termelétricos, classificados como Infraestrutura urbana.

Apesar de as classes que representam a antropização (Agricultura, Infraestrutura urbana e Mineração) não cobrirem 50% do território do município, essas classes apresentam valor alto em relação à Vegetação campestre, demonstrando que a área sofre significativo impacto de ação humana.

Tabela 5. Quantitativo da área das classes.

Classe	Área (%)	Área (km ²)
Água	1	8,95
Floresta	26	243,05
Vegetação campestre	30,9	288,92
Agricultura	40,3	376,69
Infraestrutura urbana	0,6	5,66
Mineração	1,3	12,04

Estimativa de biomassa e carbono

A classificação gerada para o município de Candiota foi utilizada para identificar especialmente áreas de mineração considerando que nestas áreas há liberação uma certa quantidade de compostos poluentes na atmosfera tanto em

forma gasosa como particulada, tais como hidrocarbonetos, óxidos de enxofre e nitrogênio, metano e monóxido de carbono. A Figura 3 apresenta os resultados para a distribuição do CO₂Flux, assumindo valores na faixa de 0,88 e – 0,45, e do XCH₄ médio, com valores na faixa de

1829 ppb na primavera e 1808 ppb no outono de 2019 a 2022. É possível identificar que a média anual de XCH₄ apresenta valores mais elevados nas áreas norte e central do município, e mais baixos no extremo sul. Em contrapartida, os valores do índice de CO₂Flux são mais elevados onde os de metano são menores, indicando uma área de maior sequestro de carbono pela vegetação. As áreas de infraestrutura urbana, a maioria das áreas agrícolas, de mineração e outras atividades antropogênicas, com os empreendimentos termelétricos que consomem grande quantidade de combustíveis fósseis, se encontram distribuídas no centro e norte do município, justamente onde foram observados altos valores de XCH₄, indicando uma distribuição espacial do poluente consistente com a distribuição de áreas impactadas por ação antrópica. De acordo com estudo recente, as emissões antropogênicas de metano derivadas de atividades agropecuárias contribuíram com mais de 89% do total de emissões de metano na área de estudo no ano de 2019 (SEEG, 2022), o que explica os valores

elevados de XCH₄ relacionados às regiões de forte atividade agrícola.

Ao analisar as respectivas áreas com dados de CO₂Flux é possível identificar baixos valores de sequestro de carbono devido à proximidade com áreas de infraestrutura urbana, mineração e áreas agrícolas com solo exposto, principalmente quando comparadas à região sul, que apresenta mais áreas de vegetação natural, está sob menor influência de atividades humanas (Figura 2) e apresenta valores mais elevados de CO₂Flux (Figura 3). Sendo assim, as distribuições espaciais de XCH₄ e CO₂Flux apresentam um padrão semelhante, porém inverso. Os resultados obtidos corroboram um estudo realizado por Gong et al. (2021) que indicou que 85% das emissões de metano estão relacionadas a atividades antrópicas, além de outros trabalhos que também apresentam uma relação positiva entre os dados derivados de satélite e as emissões de metano (Wu et al., 2019; Wang et al., 2020; Kozicka et al., 2021; Zhang et al., 2022).

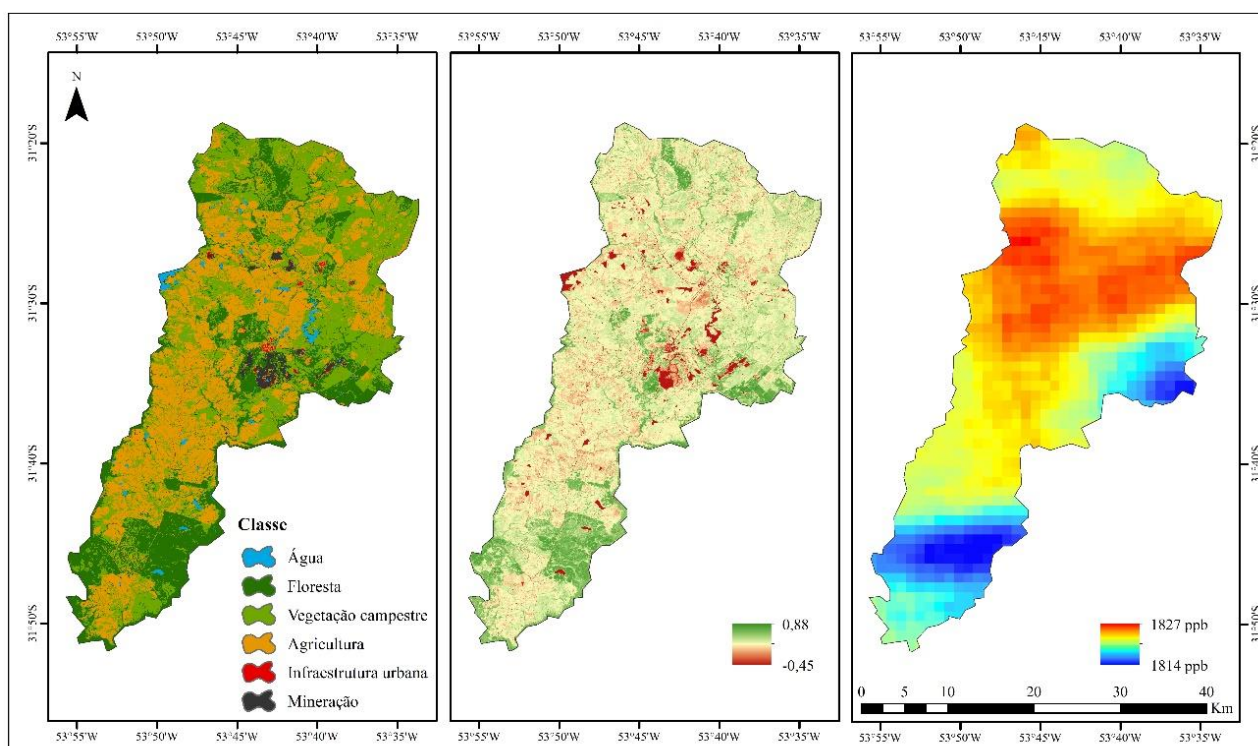


Figura 3. Distribuição de CO₂Flux e CH₄ na área de estudo entre 2019 e 2022. (a) Classificação realizada pelo método *Random Forest*, (b) CO₂Flux anual, (c) CH₄ anual.

A distribuição dos dados de XCH₄ e CO₂Flux na área de estudo nas diferentes estações do ano é apresentada na Figura 4. A variação sazonal é evidente, sendo notável que as distribuições de XCH₄ e CO₂Flux nas diferentes estações apresenta comportamento semelhante com a distribuição anual. No geral, a concentração

de metano é maior nos meses mais quentes (primavera e verão) e menor nos mais frios. Os seus máximos estão concentrados na região central do município, onde há forte atividade agrícola e concentra-se boa parte da infraestrutura urbana, enquanto seus baixos valores são observados na estação de inverno. A região mais ao norte do

município tem seus valores máximos de XCH₄ no inverno e na primavera e apresenta pouca variação nas outras estações. A região extremo sul do município possui um padrão que independe da

estação do ano, o que provavelmente está relacionado à existência de vegetação nativa e pouca interferência humana.

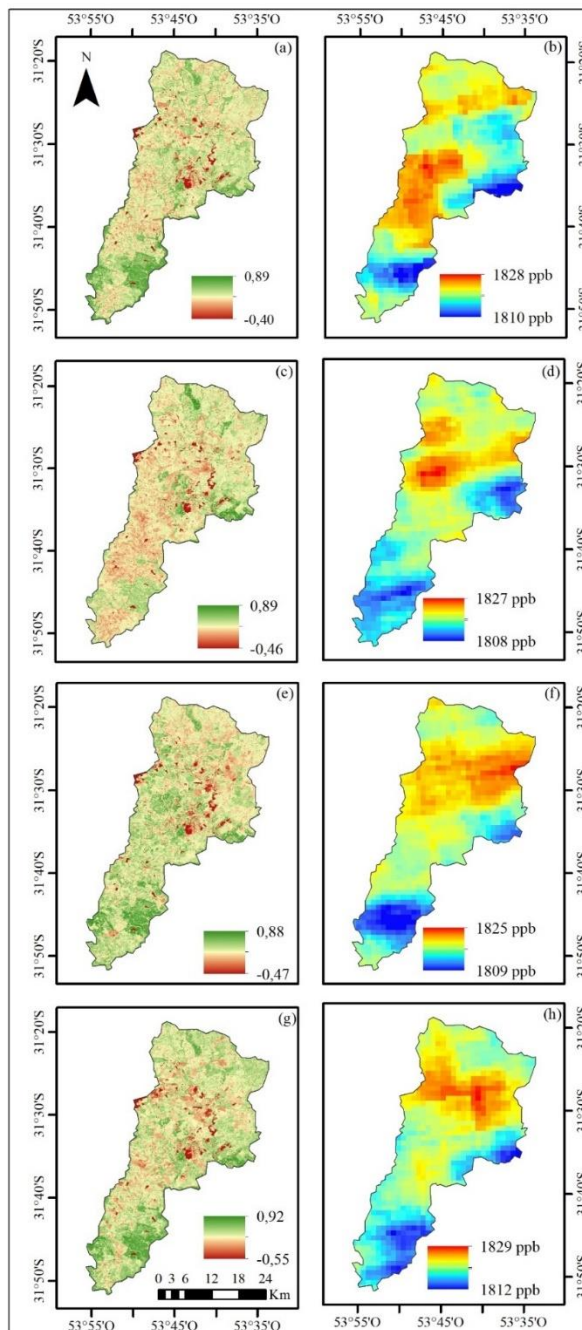


Figura 4. Distribuição de CO₂Flux e CH₄ na área de estudo entre 2019 e 2022. (a) CO₂Flux verão, (b) CH₄ verão, (c) CO₂Flux outono, (d) CH₄ outono, (e) CO₂Flux inverno, (f) CH₄ inverno, (g) CO₂Flux primavera, (h) CH₄ primavera.

Para identificar as características de variação temporal das condições de CH₄ e CO₂Flux na área de estudo foram selecionadas duas áreas representativas: Uma área de mineração (próxima

à Mina Candiota) e uma área de Agricultura (região ao norte do município). Os resultados para esta análise são apresentados na Figura 5.




Figura 5. Variação temporal de CO₂Flux e CH₄ na área de estudo. (a) CH₄ Mineração, (b) CO₂Flux Mineração, (c) CH₄ Agricultura, (d) CO₂Flux Agricultura.

A partir dos padrões obtidos, podem ser identificadas algumas características. Enquanto observa-se um crescimento de XCH₄ em diferentes taxas, observa-se um decréscimo de CO₂Flux em ambas as regiões. O crescimento de taxas de metano é semelhante nas duas áreas quando comparadas regiões de Mineração e de Agricultura. O aumento médio para a região de Mineração foi cerca de 9,4 ppb de CH₄ por ano, e na região intitulada Agricultura, cerca de 9,3 ppb ao ano. A diferença entre os valores máximo e mínimo de XCH₄ ao longo de um ano é de aproximadamente 84 ppb na região de Mineração e de cerca de 66 ppb na região de Agricultura. Wuebbles (2002) indica que práticas agrícolas, uso de energia e distribuição da população humana estão entre os fatores responsáveis pelas variações de metano ao longo do ano.

Ao analisarmos a variação sazonal, o XCH₄ tem seus maiores valores na primavera e verão, apresentando maior pico em janeiro de 2022 (~1905 ppb) na área de Mineração, fenômeno consistente com as observações de satélite. A baixa concentração de metano observada no inverno deve-se à sazonalidade das emissões de zonas de agricultura.

Já o CO₂Flux apresenta um comportamento bem diferente. Além do decréscimo ao longo dos três anos analisados, ao compararmos as duas regiões a sazonalidade encontra-se mais presente na região de Agricultura. O CO₂Flux inicia seu

decréscimo no mês de dezembro, início do verão (sazonalidade mais presente na região de Agricultura). Ao longo de um ano a variação de CO₂Flux é de aproximadamente 0,14 na região de mineração e de cerca de 0,24 na região de Agricultura.

Conclusões

Este trabalho teve como um dos objetivos realizar a classificação supervisionada de uso do solo em áreas impactadas por práticas de exploração e queima de carvão a partir de dados de sensoriamento remoto. Os resultados da classificação, com o uso de GEOBIA e de técnicas de segmentação de imagens, mostrou-se eficiente. Devido à extensão agrícola da área de estudo ser predominante e as áreas de mineração e infraestrutura urbana serem menores no processamento das classes e pela semelhança das respostas espectrais dos alvos, essa última, apresentou menor acurácia. Contudo, devido aos percentuais obtidos nas demais classes mapeadas identificou-se uma alta eficiência de classificação pelo método empregado, sendo evidente a precisão obtida nas classificações das demais classes mapeadas.

O presente trabalho também apresentou um estudo sobre a distribuição temporal e espacial das concentrações de carbono na área de estudo. Os resultados encontrados apontaram que a distribuição de XCH₄ é mais alta no centro e no

norte de Candiota, e mais baixa ao sul. Diante dos dados obtidos pôde-se concluir que a distribuição espacial de XCH₄ tem relação com a distribuição de atividades agrícolas e de produção de energia. Além disso, o XCH₄ é geralmente mais alto no verão e mais baixo no inverno. Ao analisar as duas regiões com os dados de XCH₄, observou-se que em geral o XCH₄ apresenta uma sazonalidade temporal, com ciclo de um ano, atingindo seus maiores valores no verão e menores no inverno. Porém algumas médias mensais das observações de XCH₄ encontraram-se fora do padrão sazonal, e precisarão ser mais bem exploradas através de medições *in loco* das emissões e sumidouros de gases de efeito estufa em torno dos empreendimentos.

O crescimento e o decréscimo anual e a amplitude de XCH₄ e CO₂Flux, respectivamente, variam em função das diferentes regiões indicando a dependência entre as variáveis e as atividades antrópicas.

Agradecimentos

Os autores agradecem a Universidade Federal do Rio Grande do Sul (UFRGS) pelo apoio. Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) processo número 88887.718053/2022-00.

Referências

Achanta, R.; Sússtrunk, S. 2017. Superpixels and Polygons using Simple Non-Iterative Clustering. 2017 IEEE Conference on Computer Vision and Pattern Recognition [online]. Disponível: doi: 10.1109/CVPR.2017.520. Acesso: 23 out. 2023.

Alvares, C. A. et al. 2013. Köppen's climate classification map for Brazil. Meteorologische Zeitschrift [online] 22. Disponível: DOI: 10.1127/0941-2948/2013/0507. Acesso: 23 out. 2023.

Apituley, A. et al. 2021. Sentinel-5 precursor/TROPOMI Level 2 Product User Manual Methane. Royal Netherlands Meteorological Institute. Disponível: <https://sentinel.esa.int/documents/247904/2474726/Sentinel-5P-Level-2-Product-User-Manual-Methane.pdf/1808f165-0486-4840-ac1d-06194238fa96>. Acesso: 23 out. 2023.

Banko, G. 1998. A review of assessing the accuracy of classification of remotely sensed data and methods including remote sensing data in forest inventory. In International Institute for Applied Systems Analysis. Disponível:

<https://core.ac.uk/reader/33897040>. Acesso: 23 out. 2023.

Baptista, G. M. M. 2003. Validação da modelagem de sequestro de carbono para ambientes tropicais de cerrado, por meio de dados AVIRIS e HYPERION. In: XI SBSR, Belo Horizonte. Anais [...]. São José dos Campos: INPE, 2003. p. 1037-1044. Disponível: http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2002/09.07.21.45/doc/10_002.pdf. Acesso: 23 out. 2023.

Beamish, A. et al. 2020. Recent trends and remaining challenges for optical remote sensing of Arctic tundra vegetation: A review and outlook. Remote Sensing of Environment [online] 246. Disponível: <https://doi.org/10.1016/j.rse.2020.111872>. Acesso: 25 out. 2023.

Bizon, A. R. et al. 2020. Integration Statistical Systems for Land Cover Mapping in Southern Brazil. Geospatial Technologies and Geographic Information Science for Crisis Management (GIS), Blacksburg, VA, USA, mai. 2020.

Canavesi, V.; Ponzoni, F. J.; Valeriano, M. M. 2010. Estimativa de volume de madeira em plantios de Eucalyptus spp. utilizando dados hiperespectrais e dados topográficos. Revista Árvore [online] 34. Disponível: <https://doi.org/10.1590/S0100-67622010000300018>. Acesso: 01 nov. 2023.

Carvalho, W. S.; Filho, F. J. C. M.; Santos, T. L. 2021. Uso e cobertura do solo utilizando a Plataforma Google Earth Engine (GEE): Estudo de caso em uma Unidade de Conservação. Brazilian Journal of Development [online] 7. Disponível: DOI:10.34117/bjdv7n2-243. Acesso: 23 out. 2023.

Currihuinca, L. E. S.; Chaves, J. M.; Rocha, W. J. S. F.; Lobão, J. S. B.; Falcão, P. M. 2021. Identificação das Dunas do Atacama (Norte do Chile) a partir da avaliação de três algoritmos no Google Earth Engine. Revista Brasileira de Geografia Física [online] 14. Disponível: <https://doi.org/10.26848/rbgf.v14.6.p3294-3315>. Acesso: 25 out. 2023.


Gamon, J. A.; Penuelas, J.; Field, C. B. 1992. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. Remote Sensing of Environment [online] 41. Disponível: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S). Acesso: 23 out. 2023.

Gong, S.; Shi, Y. 2021. Evaluation of comprehensive monthly-gridded methane emissions from natural and anthropogenic sources in China. Science of The Total

- Environment [online] 784. Disponível: <https://doi.org/10.1016/j.scitotenv.2021.147116>. Acesso: 23 out. 2023.
- Hamud, A. M.; Shafri, H. Z. M.; Shaharum, N. S. N. 2021. Monitoring Urban Expansion and Land Use/Land Cover Changes In Banadir, Somalia Using Google Earth Engine (GEE). IOP Conf. Series: Earth and Environmental Science [online] 767. Disponível: DOI 10.1088/1755-1315/767/1/012041. Acesso: 23 out. 2023.
- Huang, S.; Tang, L.; Hupy, J. P.; Wang, Y.; Shao, G. 2020. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. Journal of Forestry Research [online] 32. Disponível: <https://doi.org/10.1007/s11676-020-01155-1>. Acesso: 24 out. 2023.
- IBGE – Instituto Brasileiro de Geografia e Estatística. MANUAL TÉCNICO DA VEGETAÇÃO BRASILEIRA 2012.
- Köppen, W., 1936: Das geographische System der Klimate. KÖPPEN, W., R. GEIGER (Eds.): Handbuch der Klimatologie. Gebrüder Bornträger, Berlin, 1, 1–44, part C.
- Kozicka, K.; Gozdowski, D.; Wójcik-Gront, E. 2021. Spatial-Temporal Changes of Methane Content in the Atmosphere for Selected Countries and Regions with High Methane Emission from Rice Cultivation. Atmosphere-Basel [online] 12. Disponível: <https://doi.org/10.3390/atmos12111382>. Acesso: 23 out. 2023.
- Landis, J. R.; Koch, G. G. 1977. The measurement of observer agreement for categorical data. Biometrics [online] 33. Disponível: <https://doi.org/10.2307/2529310>. Acesso: 23 out. 2023.
- Lima, J.; Lage-Pinto, F.; Bernini, E. 2023. Spatial-temporal distribution of mangrove species in the estuary of the Mamanguape river in the state of Paraíba, Brazil. Regional Studies in Marine Science [online] 66. Disponível: <https://doi.org/10.1016/j.rsma.2023.103166>. Acesso: 25 out. 2023.
- Liu, Z.; Yang, J.; Huang, X. 2023. Landsat-derived impervious surface area expansion in the Arctic from 1985 to 2021. Science of The Total Environment [online]. Disponível: <https://doi.org/10.1016/j.scitotenv.2023.166966>. Acesso: 25 out. 2023.
- Lou, P. et al. 2020. An Optimized Object-Based Random Forest Algorithm for Marsh Vegetation Mapping Using High-Spatial-Resolution GF-1 and ZY-3 Data. Remote Sensing [online] 12. Disponível: <https://doi.org/10.3390/rs12081270>. Acesso: 30 out. 2023.
- Ni, Q.; Zhou, M.; Wang, J.; Wang, T.; Wang, G.; Wang, P. 2023. Intercomparison of CH4 Products in China from GOSAT, TROPOMI, IASI, and AIRS Satellites. Remote Sensing [online] 15. Disponível: <https://doi.org/10.3390/rs15184499>. Acesso: 05 mar. 2024.
- Peuker, K.; Fagundes, L. Emissões Fugitivas da Mineração e do Tratamento de Carvão Mineral. In: Primeiro Inventário Brasileiro de Emissões Antrópicas de Gases de Efeito Estufa, 2006.
- RIO GRANDE DO SUL. Carta-compromisso com a agenda mundial para a descarbonização. Porto Alegre, 2021.
- Ryu, J.; Oh, D.; Cho, J. 2021. Simple method for extracting the seasonal signals of photochemical reflectance index and normalized difference vegetation index measured using a spectral reflectance sensor. Journal of Integrative Agriculture [online] 20. Disponível: [https://doi.org/10.1016/S2095-3119\(20\)63410-4](https://doi.org/10.1016/S2095-3119(20)63410-4). Acesso: 24 out. 2023.
- Santos, A. S. R. M. et al. 2019. Métodos de Classificação Supervisionada Aplicados no Uso e Ocupação do Solo no Município de Presidente Médice – RO. Biodiversidade [online] 18. Disponível: <https://periodicoscientificos.ufmt.br/ojs/index.php/biodiversidade/article/view/8242>. Acesso: 23 out. 2023.
- Saunois, M. et al. 2020. The Global Methane Budget 2000–2017. Earth System Science Data [online] 12. Disponível: <https://doi.org/10.5194/essd-12-1561-2020>. Acesso: 23 out. 2023.
- SEEG - Sistema de Estimativa de Emissões de Gases de Efeito Estufa. Base de dados: Emissões Totais, 2022.
- Singh, R. P. et al. 2016. Normalized Difference Vegetation Index (NDVI) Based Classification to Assess the Change in Land Use/Land Cover (LULC) in Lower Assam, India. International Journal of Advanced Remote Sensing and GIS [online] 5. Disponível: <https://doi.org/10.23953/cloud.ijarsg.74>. Acesso: 23 out. 2023.
- Trenchev, P.; Dimitrova, M.; Avetisyan, D. Hüge. 2023. CH4, NO2 and CO Emissions from Coal Mines in the Kuznetsk Basin (Russia) Detected by Sentinel-5P. Remote Sensing [online] 15. Disponível: <https://doi.org/10.3390/rs15061590>. Acesso: 05 mar. 2024.

- Wang, J.; Sun, C.; Wang, G.; Zou, M.; Tan, T.; Liu, K.; Chen, W.; Gao, X. 2020. A fibered near-infrared laser heterodyne radiometer for simultaneous remote sensing of atmospheric CO₂ and CH₄. *Optics and Lasers in Engineering* [online] 129. Disponível: <https://doi.org/10.1016/j.optlaseng.2020.106083>. Acesso: 23 out. 2023.
- Wang, X. et al. 2019. Land-Cover Classification of Coastal Wetlands Using the RF Algorithm for Worldview-2 and Landsat 8 Images. *Remote Sensing* [online] 11. Disponível: <https://doi.org/10.3390/rs11161927>. Acesso: 25 out. 2023.
- Weber, E. J. et al. *Uso e Cobertura Vegetal do Estado do Rio Grande do Sul – Situação em 2015. 1ª Edição, Porto Alegre - UFRGS IB Centro de Ecologia, 2018.*
- Wu, X.; Zhang, X.; Chuai, X.; Huang, X.; Wang, Z. 2019. Long-Term Trends of Atmospheric CH₄ Concentration across China from 2002 to 2016. *Remote Sensing* [online] 11. Disponível: <https://doi.org/10.3390/rs11050538>. Acesso: 23 out. 2023.
- Wuebbles, D. J.; Hayhoe, K. 2001. Atmospheric methane and global change. *Earth-Science Reviews* [online] 57. Disponível: [https://doi.org/10.1016/S0012-8252\(01\)00062-9](https://doi.org/10.1016/S0012-8252(01)00062-9). Acesso: 23 out. 2023.
- Zhang, F.; Yang, X. 2020. Improving land cover classification in an urbanized coastal area by random forests: The role of variable selection. *Remote Sensing of Environment* [online] 251. Disponível: <https://doi.org/10.1016/j.rse.2020.112105>. Acesso: 25 out. 2023.
- Zhang, J.; Han, G.; Mao, H.; Pei, Z.; Ma, X.; Jia, W.; Gong, W. 2022. The Spatial and Temporal Distribution Patterns of XCH₄ in China: New Observations from TROPOMI. *Atmosphere* [online] 13. Disponível: <https://doi.org/10.3390/atmos13020177>. Acesso: 23 out. 2023.

- 2.3.2 *Artigo 2: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D; FONTANA, D. C.; MORAES, O. L. L. Assessment of the relationship between biomass and carbon near coal mining and combustion areas.*



Assessment of the relationship between biomass and carbon near coal mining and combustion areas

Journal:	<i>International Journal of Remote Sensing</i>
Manuscript ID	Draft
Manuscript Type:	IJRS Research Paper
Date Submitted by the Author:	n/a
Complete List of Authors:	Lüdtke Paim, Bruna; Federal University of Rio Grande do Sul, Marques Alves, Rita de Cássia; Federal University of Rio Grande do Sul, Geoscience Institute Dutra de Lima, Bianca; Federal University of Rio Grande do Sul, Geoscience Institute Fontana, Denise; UFRGS, DPFA Leal de Moraes, Osvaldo Luiz; Ministry of Science Technology and Innovations, Department of Climate and Sustainability
Keywords:	remote sensing, carbon dioxide, Coal fired power plants
Keywords (user defined):	Remote Sensing, Carbon, Mining

SCHOLARONE™
Manuscripts

ABSTRACT

The aim of this study is to quantify the carbon stored in the environment of mining areas. Although many studies describe the incorporation of forest fragments into biomass, there is still a lack of approaches that assess the ecological processes of biomass and carbon incorporation near the areas of interest in this study. Based on these estimates, a model is constructed to estimate biomass and carbon incorporation rates in natural pastures and afforested areas. The method combines in-situ measurements and the use of remote sensing techniques using spectral bands and vegetation indices. The results of the biophysical variables collected in the field show that the variance of biomass and carbon was different at the different sampling sites, possibly due to soil and vegetation management at each site. In terms of seasons, it was found that there was no statistically significant difference between the means of the two variables analyzed.

1.INTRODUCTION

Geoprocessing and remote sensing are important tools for environmental planning. These techniques provide data with unique spatial and temporal coverage that are extremely useful for monitoring the Earth's surface, as they allow the processing of vegetation indices related to the production and abundance of plant biomass. Several authors have used remote sensing to estimate biomass values, using different types of spectral data from active and passive remote sensors as sources. It is well known that remote sensing data combined with field data provide very accurate estimates of biomass and carbon stocks. (BAKER et al. 2010, LE MAIRE et al. 2011).

Previous work has emphasized the use of vegetation indices, which are proposed to infer from the spectral properties of vegetation to its biophysical parameters. These indices are the result of radiometric transformations of spectral bands of orbital images and can be useful for the calculation and comparison of biophysical data collected in the field, such as biomass and carbon (SILVA, 2015). One of the most commonly used indices in the literature is the NDVI (Normalized Difference Vegetation Index), which was proposed by Rouse et al. (1973) to reduce the effects of atmospheric scattering by using the normalized difference between two spectral bands, the near infrared and the red band (THENKABAIL et al., 1999). For carbon interference, Gamon et al. (1992) proposed the PRI (Photochemical Reflectance Index), which responds to changes in carotenoid pigments in the foliage that serve as an indicator of the efficiency of utilization of active photosynthetic light or the rate of carbon dioxide stored by the foliage per unit of absorbed energy. The CO₂Flux index is then obtained by integrating the PRI with the NDVI (RAHMAN et al., 2000), which makes it

possible to take into account the absorption characteristics resulting from carbon sequestration.

Projected and ongoing climate change is affecting carbon sequestration by vegetation due to the challenges associated with changing weather patterns and the frequent occurrence of extreme weather events associated with soil and vegetation degradation. Terrestrial ecosystems sequester about 30% of CO₂ emitted by human activities annually (TERRER et al., 2021; FRIEDLINGSTEIN et al., 2020), and an accurate estimate of aboveground vegetation biomass is essential for ecosystem monitoring and control (Li et al., 2021). The use of spectral bands is then used in research to predict carbon stocks and plant biomass (HUA et al., 2021) to map the aboveground biomass of crops, forests and pastures, which is essential in the field of agricultural remote sensing (FANG et al., 2021).

Although many studies describe the incorporation of forest fragments into biomass (SHARIFI et al., 2023; MUNYATI et al., 2022; LI et al., 2021; VELOSO et al., 2020), there is still a lack of approaches that assess the ecological processes of biomass and carbon incorporation in the vicinity of extraction areas. With the aim of assessing terrestrial fluxes, this work proposes to quantify the carbon stored by the environment and, from this, to develop a model to estimate biomass and carbon incorporation rates in natural and planted pastures near thermoelectric projects and coal mining using spectral bands and vegetation indices, as mining activities strongly affect soil quality and plant growth, as they can alter soil microbial activity and significantly inhibit plant growth.

2.METHODOLOGY

2.1 Study area

The study area (Figure 1) is located in the municipality of Candiota in the southern region of the Brazilian state of Rio Grande do Sul and covers 935 km². The area is located in the Pampa biome, the Campos Sulinos ecoregion, and includes forest and grassland formations. It is worth noting that much of this native vegetation is being altered, as the grassland vegetation has been progressively replaced for many years by cultivated

pastures, agricultural crops and afforestation. According to MapBiomas (2023), the Pampa biome has already lost about 32% of its original vegetation cover since 1985.

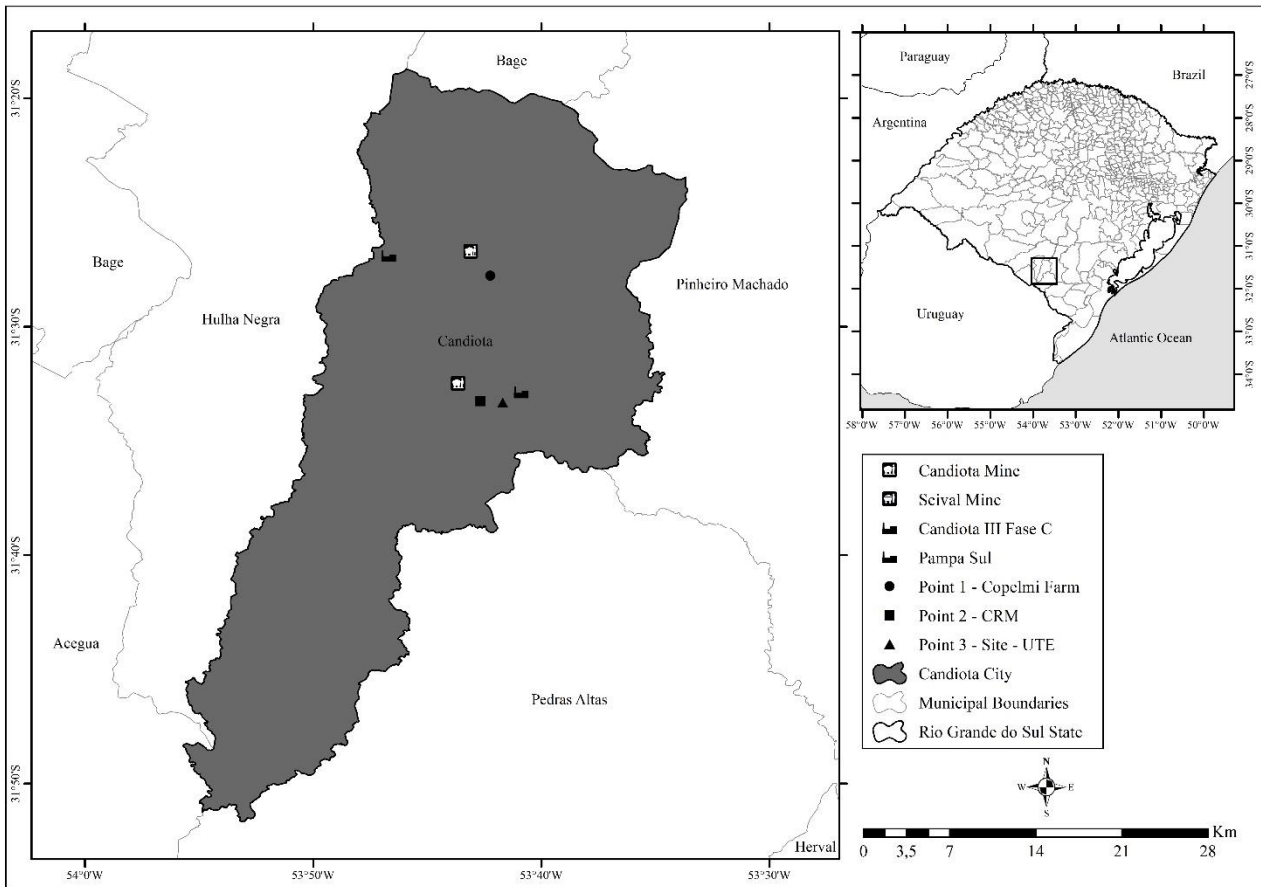


Figure 6: Delimitation of the study area and location of the sampling points. Municipality of Candiota, RS.

According to Alvares et al. (2013), the climate of the region is of type Cfa: subtropical (zone C), humid (f) and with hot summers (a), according to the criteria of the Köppen climate classification (1936). The letter “f” means that the monthly precipitation is distributed throughout the year and there is no dry season. The letter “a” means that the average temperature of the warmest month is above or equal to 22 °C and the average temperature of the coldest month is between -3 and 18 °C.

2.2 Field Campaigns: Measurement of aboveground biomass, sample selection, preparation and analysis

The selection of sampling points was based on prevailing wind direction and proximity to thermoelectric and mining projects, as well as accessibility and availability of infrastructure and transportation. Three sampling areas were selected: Point 1 (Copelmi Farm) - facing the prevailing wind direction; Point 2 (CRM) - coal mine; and Point 3 (Site – UTE) - near the plant, facing the prevailing wind direction (Figure 1). At the sampling points, the plant

composition is described by grass species: Point 1, with a greater dominance of *Lolium Multiflorum* Lam. (Italian ryegrass) and *Lolium Perene* (Perennial ryegrass) (Figure 2a), at this point the vegetation was managed by cutting back the grass to feed the animals; point 2, with a greater dominance of *Urochloa Decumbens* (Signal grass) (Figure 2b), at this point there was no vegetation management, the grass grew freely without any kind of vegetation or soil control; and point 3, with a greater dominance of *Andropogon Lateralis* (Caninha grass) (Figure 2c), a point of native field condition, with the presence of animals, but without herd control.




Figure 7: Plant composition of the sampling sites (a) point 1 (Copelmi Farm), (b) point 2 (CRM) and (c) point 3 (Site – UTE).

For the collection of plant tissue samples, the fixed plot method (SANQUETTA et al., 2014) was used and four plots of 25 m in length and 10 m in width were defined in each area, for a total of 12 plots. Vegetation was collected randomly in each field plot selected according to the method proposed by (SALMAN et al., 2006), where the plant material was cut at ground level using a 50 x 50 cm (0.25 m²) wooden frame, applying the "quadrat method".

The field campaigns were carried out in the spring and winter seasons, on October 14, 2022 and July 28, 2023, respectively. These periods were chosen to check for possible fluctuations in biomass and carbon between the two seasons. In each campaign, 12 samples were taken, 1 per sample point, with a total of 24 samples in the study.

The plant material was stored in paper bags and weighed to obtain the green biomass and then transferred to greenhouses with air circulation to obtain the dry biomass. The material was dried at a temperature of 40° until it reached a constant weight and quantified

in terms of mass. The dry biomass samples were then ground and analyzed for carbon content by dry combustion in a CN analyzer (Flash 2000 IRMS, Thermo Fisher Scientific). The equivalent carbon content was calculated from a conversion rate multiplied by the carbon stock (Equation 1), as described by the IPCC (2003). The carbon contents were analyzed using descriptive and bivariate statistics.

$$CO_{2eq} = C * \frac{44}{12} \quad (1)$$

where CO_{2eq} is the Carbon equivalent (%), C is the Carbon content (%) and 44 and 12 are the atomic mass of CO_2 and Carbon respectively.

2.3 Estimation of biomass and carbon from spectral data

The estimate of the surface carbon stock was obtained from optical data from time series of the MSI (Multispectral Instrument) sensor on board the Sentinel-2A platform. These estimates were generated by applying models between the optical data (spectral bands and vegetation indices) and the surface biomass and carbon stock parameters of the field plots. In this study, the average of data from satellite images obtained up to ± 4 days after the ground measurements was used, a method similar to that of Gargiulo et al. (2023). Table 1 shows the field survey data and the images used for the correlation analysis.

Table 1: Acquisition periods and images for the extraction of spectral data and correlations with biophysical data.

Source	Spring	Summer
Sentinel-2a images	2022/10/14	2023/07/28
	2022/10/12 – 2022/10/15	2023/07/21 – 2023/07/28

The images were subjected to a pre-processing procedure in which an atmospheric correction was applied to convert the reflectance values from the top of the atmosphere into surface reflectance values.

A linear regression analysis was then performed to create a statistical model in which the biomass or carbon of the vegetation quantified in each sampling unit was the dependent variable and the values of the spectral bands and/or vegetation indices were the independent variable.

Two spectral bands and five spectral indices were tested. The spectral bands tested were the Red (B4) and Red Edge 1 (B5) bands of Sentinel-2A and the vegetation indices NDVI (Normalized Difference Vegetation Index), NDRE (Normalized Difference Red Edge Index), sPRI (Photochemical Reflectance Index - rescaled to positive values), CO₂Flux (integration of sPRI with NDVI (BAPTISTA, 2003)) and CO₂Flux_NDRE (calculated from the NDRE index). Statistical tests were performed to select the bands and indices with the most significant contribution to the composition of the regression models, as well as tests (mean absolute error - MAE; mean square error - MSE; coefficient of determination - R²) to validate the regressions and analyze errors.

3.RESULTS

3.1 Biomass and Carbon Estimation

The values of total dry biomass stored at the studied sites ranged from 49.32 to 115.04 g/m² in spring (Table 2), with an average of 78.00 ± 33.65 g/m². In winter, the biomass ranged from 69.85 to 91.63 g/m², showing less variability than in spring, but with an increase in biomass content during this period, which averaged 80.74 ± 10.89 g/m². This increase is not to be expected, as lower biomass is expected in winter. However, what may have contributed to this increase was the increase in biomass at Point 2 (CRM).

Table 2 shows a slight temporal and spatial variation – about 40% C. Carbon contents varied between 39.34 and 42.41%, with an average of $41.40 \pm 1.71\%$ in spring and in winter they were lower on average, $40.35 \pm 1.02\%$, which is due to the reduction of biomass and thus carbon in Point 1 (Copelmi Farm). In Point 2 (CRM) the biomass is higher in winter and in Point 3 (Sítio - UTE) it is the same in both periods. This pattern could be due to the botanical composition, because at this point, where the biomass has stabilized, the vegetation is predominantly composed of natural pasture, in contrast to the other two points where there was a decrease and an increase and the vegetation is composed of planted pasture.

Table 2: Values of the biophysical variables at the three sampling points in the two sampling periods. Municipality of Candiota, period October 2022 and July 2023. Mean values marked with the same lowercase letter in the rows do not differ from each other according to Tukey's test with a probability of 5%. Variances marked with the same capital letter in the rows do not differ from each other with a probability of 5% using Levene's test.

Sample Unit	Carbon content (%)		Biomass total (g/m ²)		Carbon stock (g/m ²)		CO ₂ eq (g/m ²)	
	Spring	Winter	Spring	Winter	Spring	Winter	Spring	Winter
Point 1	39,42	40,35	115,04	80,74	45,35	32,58	421,81	296,05
Point 2	42,36	39,34	49,32	91,63	20,89	36,04	180,84	335,96
Point 3	42,41	41,37	69,64	69,85	29,53	28,90	255,35	256,13
Average	41,40a	40,35a	78,00b	80,74b	31,92c	32,51c	286,00d	296,05 d
SD	1,71	1,02	33,65	10,89	12,40	3,57	123,37	39,92
CV	4,14A	2,52A	43,14B	13,49B	38,86C	10,98C	43,14D	13,48D

Variations in biomass stocks were more significant compared to carbon content with coefficients of variation of 43.14% (spring) and 13.49% (winter). This factor determined the greatest variation in carbon stocks, which ranged from 20.89 to 45.35 g/m² in the sample units, with an average of 31.92 ± 12.40 g/m² in spring. This carbon stock corresponds on average to the removal of 286 g CO₂eq/m² of carbon dioxide. According to the IPCC (2006), the organic carbon content of natural and planted pastures is usually around 47% and is therefore similar to the average value determined in this study, which was only 5.6% below the known value in spring and 6.65% in winter.

The biomass values found in this study are in the range of the values of other authors for pasture areas. Choi et al. (2023) found an average of 66.5 g/m² aboveground biomass when analyzing the aboveground and belowground biomass of planted pasture over three years. Amarsaikhan et al. (2023) determined an average of 77.08 g/m² of biomass for pastureland in a forest steppe area in July, summer in Mongolia. Guerini Filho et al. (2019) found 347.20 g/m² biomass for natural pasture in an experimental area with a rotational grazing system (a management system that divides the pasture into paddocks).

Many factors, both natural and man-made, can influence the growth of vegetation and thus the state of biomass at the selected study site. Kumari et al. (2019), comparing reclamation sites in coal mines, found that the above-ground biomass and carbon content of legumes was significantly higher than that of grasses. Vegetation with a larger amount of plant biomass respire more intensively and favors the photosynthesis process of the plant (RADOZ et al., 2023), which consequently favors the uptake of atmospheric CO₂ by the vegetation.

Using the test for homogeneity of variances, also called Levene's test, which is often used for comparisons between two or more groups (LEVENE, 1960; BROWN and FORSYTHE, 1974), it was found that no significant differences were observed in the variances of carbon content, biomass and carbon collected between seasons ($p > 0.05$). However, the variance of biophysical variables differed among sampling sites, i.e. there was no homogeneity, possibly due to soil and vegetation management activities at each site ($p < 0.05$).

Using the Tukey test, a statistical test for comparing mean values, it was found that there was no statistically significant difference between the spring and winter mean values for the biophysical variables. No changes in land cover and land use were observed at the sampling sites during the two field studies. Crops grown on the planted pastures include ryegrass (*Lolium multiflorum*), a fast-growing annual or perennial grass native to Europe but grown in many regions of the world, both in dry and rainy areas (KIM et al., 2019). In southern Brazil, ryegrass is of great importance in livestock farming (GRAMINHO et al., 2019). Due to its rapid growth, strong regenerative capacity, high yield and great adaptability, it is often used as a pioneer plant for the restoration of vegetation in mining areas (CHEN et al., 2023). According to Bo et al. (2022), it is one of the plants with the highest production of fresh biomass and dry matter, which also sequesters carbon and increases the stability of soil aggregates (KEMESYTE et al., 2023).

The lower biomass at Point 1 is possibly due to winter, when reduced sunlight and lower temperatures lead to lower vegetation growth. The yield of ryegrass is sensitive to climate variability; drought episodes in spring, when it is normally in the phenological phase of flowering and seed formation, can lead to low productivity (KIM, 2019), and this sensitivity to drought is a characteristic of grass species (JERONIMO et al.; 2014). According to Kostrzewska et al. (2020), this sensitivity to water scarcity reacts mainly with low tillage, which can lead to lower biomass. At Point 3, where biomass values are similar between seasons, the ground cover is a natural pasture native to this pampas biome.

3.2 Comparison of spectral data with biophysical variables

The basic statistics of the values of the vegetation indices and the Sentinel-2A spectral bands obtained in the plots and during the sampling periods are shown in Table 3. The value of the coefficient of variation CV (%) was higher for band 5 (red edge) than for band 4 (red), indicating a greater heterogeneity in the spectral values of this band. Among the spectral indices, the CO₂Flux_NDRE index, calculated from the combination of the NDRE and sPRI indices, was the one with the greatest heterogeneity. The vegetation index

NDVI was more sensitive to variations in biomass, with maximum and minimum values of 0.72 and 0.44, respectively (Table 3).

Table 3: Spectral band values and vegetation indices for the three sampling sites in the two sampling periods. Municipality of Candiota, period October 2022 (Spring) and July 2023 (Winter). Average, maximum and minimum values and variability statistics (SD - standard deviation and CV - coefficient of variation) observed in the indices and bands of the Sentinel-2A sensor in the plots and sampling periods.

Sample Unit	red		red edge		NDVI		NDRE		sPRI		CO ₂ Flux		CO ₂ Flux_NDRE	
	Spring	Winter	Spring	Winter	Spring	Winter	Spring	Winter	Spring	Winter	Spring	Winter	Spring	Winter
Point 1	0,16	0,05	0,22	0,08	0,46	0,67	0,32	0,50	0,55	0,59	0,25	0,39	0,18	0,29
Point 2	0,13	0,03	0,17	0,05	0,45	0,58	0,34	0,45	0,53	0,52	0,24	0,30	0,18	0,23
Point 3	0,17	0,05	0,23	0,10	0,44	0,72	0,31	0,50	0,55	0,62	0,25	0,44	0,17	0,32
Maximum	0,17	0,05	0,23	0,10	0,46	0,72	0,34	0,50	0,55	0,62	0,25	0,44	0,18	0,32
Minimum	0,13	0,03	0,17	0,05	0,44	0,58	0,31	0,45	0,53	0,52	0,24	0,30	0,17	0,23
Average	0,15	0,04	0,21	0,08	0,45	0,65	0,32	0,48	0,55	0,58	0,25	0,38	0,18	0,28
SD	0,02	0,01	0,03	0,03	0,01	0,07	0,02	0,03	0,01	0,05	0,01	0,07	0,01	0,04
CV	12,71	22,50	16,72	38,19	1,79	10,88	5,75	6,03	2,47	8,48	3,43	18,93	3,34	15,36

The correlation matrix in Table 4 shows the degree of association between the biophysical variables observed in the field and the spectral variables by the person's correlation coefficient (r). It can be seen that the biophysical variables show a weak, medium and moderate correlation with the spectral bands and the vegetation indices. The high correlation between the biomass and carbon variables ($r = 0.99$) should be emphasised, which was to be expected since the carbon value used in this analysis was derived from the dry weight of the biomass multiplied by the carbon content, the latter showing low variability.

Table 4: Correlation matrix between biophysical variables (Biom – biomass; Carb – carbon) and spectral bands and indices.

	Biom	Carb	NDVI	NDRE	sPRI	CO ₂ Flux	CO ₂ Flux_ NDRE	red	red edge
Biom	1,00								
Carb	0,99	1,00							
NDVI	0,70	0,80	1,00						
NDRE	0,79*	0,80*	1,00	1,00					
sPRI	0,30	0,30	0,70	0,60	1,00				
CO ₂ Flux	0,67*	0,67*	1,00	0,94*	0,80	1,00			
CO ₂ Flux_ NDRE	0,75*	0,75*	1,00	0,98*	0,70	0,98*	1,00		
red	0,72*	0,76*	0,90	0,94*	0,30	0,79*	0,87*	1,00	
red edge	0,71*	0,76*	0,80	0,90*	0,20	0,72*	0,82*	0,99*	1,00

* p-value < 0.05 statistically significant correlation.

The red and red edge stripes showed similar correlations for biomass, 0.72 and 0.71 respectively, and the same correlation for the carbon variable, 0.76, which are considered strong correlations according to Field (2009). The vegetation indices (NDRE and CO₂Flux_NDRE) showed a stronger correlation with both biomass and carbon. This pattern is consistent because these indices use the red edge band. This is the region of the electromagnetic spectrum where the reflectance of vegetation changes rapidly, from low values in the red to very high values in the near infrared, and is associated with several physical and chemical parameters of vegetation, including chlorophyll (HUA et al., 2021).

Studies using the red edge have obtained more accurate models for estimating and assessing aboveground biomass. Ren et al. (2011) used red edge reflectance to estimate aboveground biomass in the assessment of rangeland biomass in China and obtained a

model fit of $R^2 = 0.79$. The study using this spectral band was a suitable approach to complement the existing estimation method for aboveground green biomass in arid and semi-arid areas. Sibanda et al. (2017) investigated the robustness of different models that integrated texture features and red edge information to predict aboveground biomass of pastures under different management regimes. They created the regression algorithm and evaluated the accuracy of the results, achieving a model fit of $R^2 = 0.90$. The authors pointed out that vegetation indices for red margins can improve the accuracy of pasture biomass estimation.

3.3 Determination of estimated biomass and carbon.

Figure 3 shows the accuracy of the estimation of the biophysical variable biomass, which confirms the results of previous studies that remote sensing data can provide good estimates of biomass and carbon for pastures (GUERINI FILHO et al., 2019; CHANG et al., 2022; MUNYATI, 2022; SHARIF et al., 2023). The biomass estimate achieved better precision by the index calculated from the red edge spectrum (Equation 8, $R^2 = 0.45$, MAE = 12.05 g/m², Table 5), as did the carbon estimate (Equation 3, $R^2 = 0.45$, MAE = 4.63 g/m²), despite the two mismatched points in Figure 3 (red circle), which were estimates from sampling in spring at Point 3 (Site – UTE). This result is largely due to the relationship between the red edge band region and the chlorophyll content of the plants (FRAMPTON et al., 2013). According to Guerini Filho et al. (2019), vegetation indices derived from the reflectance of the red edge band provide higher accuracy in estimating the biomass of natural pastures compared to other spectral parameters.

Figure 3: Values of the measured biophysical variables on the y-axis and the values estimated by the model on the x-axis (a), as well as the average behavior of the measured and estimated variables.

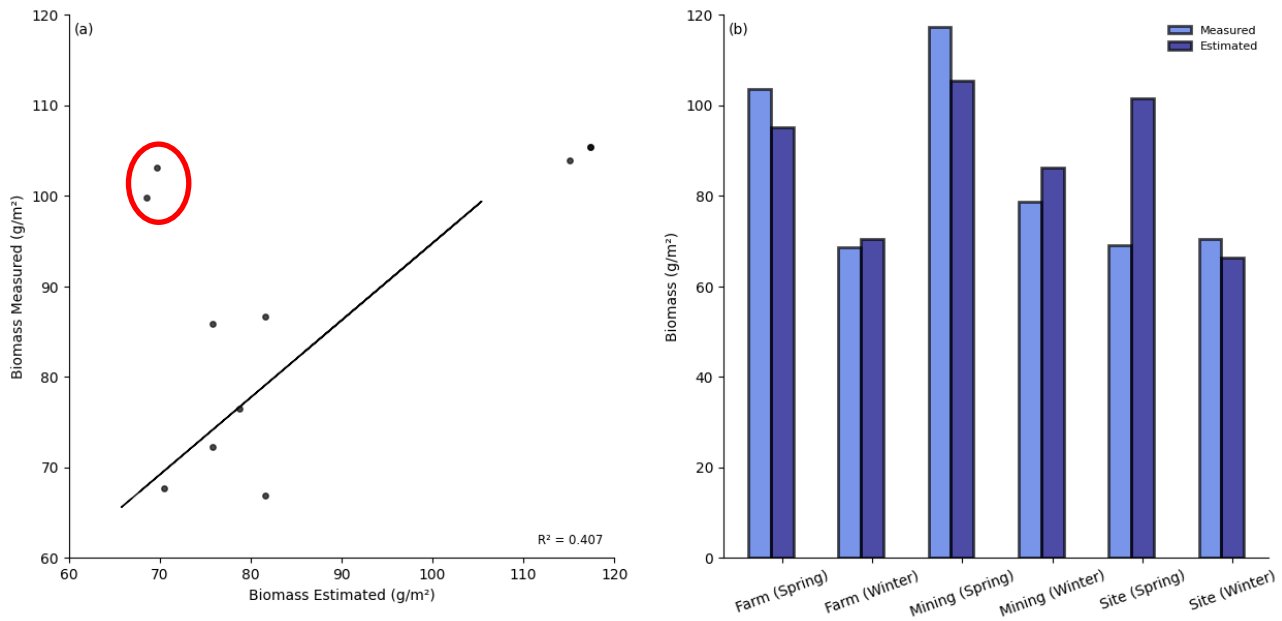


Table 5: equations derived by applying simple linear regression (equations 1 - 10) and multiple linear regression (equations 11 and 12).

	Equation	R ²	MAE (g/m ²)
1	$C = 61.1539 - 64.6680 * NDRE$	0.44	4.35
2	$C = 56.2094 - 67.2504 * CO_2Flux$	0.37	5.13
3	$C = 56.5410 - 94.1915 * CO_2Flux_NDRE$	0.45	4.63
4	$C = 25.3540 + 102.3460 * B4$	0.37	4.63
5	$C = 24.1602 + 78.2486 * B5$	0.35	4.81
6	$B = 152.7323 - 161.3405 * NDRE$	0.38	11.24
7	$B = 141.5722 - 171.3864 * CO_2Flux$	0.34	13.51
8	$B = 141.8245 - 237.5397 * CO_2Flux_NDRE$	0.41	12.05
9	$B = 64.1860 + 246.4833 * B4$	0.28	12.75
10	$B = 61.5212 + 186.8202 * B5$	0.26	13.13
	$C = 100.9387 - 291.4005 * NDRE + 331.5123 *$		
11	$CO_2Flux - 147.4293 * CO_2Flux_NDRE + 366.0946 * B4$ $- 392.6046 * B5$	0.39	4.42
	$B = 7.2778 - 11.1072 * NDRE + 176.0921 * CO_2Flux +$		
12	$81.3093 * CO_2Flux_NDRE + 80.7188 * B4 + 141.9983 *$ $B5$	0.004	29.93

Most of the vegetation indices in this study are correlated and agree with those of Sibanda et al. (2017) and Guerini Filho et al. (2019), who also found a correlation of pasture biomass with the bands in the red edge and infrared regions of the MSI Sentinel-2A data.

4.CONCLUSIONS

The aim of this study was to quantify the carbon stored by the environment and to develop a model to estimate biomass and carbon uptake in natural and vegetated grasslands near thermoelectric projects and coal mines, using spectral bands and vegetation indices. The results of the biophysical variables collected in the field show that the variance of biomass and carbon was different at the different sampling sites, possibly due to soil and vegetation management at each site, as different human activities have an impact on soil and vegetation. It was found that there is no statistically significant difference between the seasonal averages of the two variables analyzed.

This study also presents a model for estimating biomass and carbon incorporation rates, confirming previous studies that remote sensing data can be used in biomass and carbon estimates for pastures and helping to show the temporal and spatial variability of the models. The best accuracy is obtained when using data from spectral indices calculated with the red edge spectral band. The model used to estimate biomass and carbon incorporation rates performed well, with the best precision obtained from the spectral indices calculated with the red edge band, with a mean absolute error (MAE) of 12.05 g/m² and a coefficient of determination (R²) of 0.41 for biomass and an MAE of 4.63 g/m² and an R² of 0.45 for carbon.

Our research highlights the importance of vegetation control and management in areas affected by thermoelectric projects and open pit mining to support the development of measures to restore degraded areas aimed at mitigating environmental impacts. Furthermore, given the distribution of carbon through vegetation, this result raises the question of the performance and importance of this carbon for the dynamics of soils in these areas.

References:

AMARSAIKHAN, E.; ERDENEBAATAR, N.; AMARSAIKHAN, D.; OTGONBAYAR, M.; BAYARAA, B. **Estimation and mapping of pasture biomass in Mongolia using machine learning methods.** Geocarto International, 2023, 38. <https://doi.org/10.1080/10106049.2023.2195824>

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. **Köppen's climate classification map for Brazil**. Meteorologische Zeitschrift, 2013, 22. DOI: 10.1127/0941-2948/2013/0507

BAPTISTA, G. M. M. Validação da modelagem de sequestro de carbono para ambientes tropicais de cerrado, por meio de dados AVIRIS e HYPERION. In: XI SBSR, 2003, Belo Horizonte. **Anais [...]**. São José dos Campos: INPE, 2003. p. 1037-1044.

BAKER, D. J.; RICHARDS, G.; GRAINGER, A.; GONZALEZ, P.; BROWN, S.; DEFRIES, R.; HELD, A.; KELLNDORFER, J.; NDUNDA, P.; OJIMA.; SKROVSETH, P.; SOUZA JR., C.; STOLLE, F. **Achieving Forest carbon information with higher certainty: A five-part plan**. Environmental Science and Policy, 2010, 13. <https://doi.org/10.1016/j.envsci.2010.03.004>

BO, P.T.; BAI, Y.; DONG, Y.; SHI, H.; SOE HTET, M.N.; SAMOON, H.A.; ZHANG, R.; TANVEER, S.K.; HAI, J. **Influence of Different Harvesting Stages and Cereals–Legume Mixture on Forage Biomass Yield, Nutritional Compositions, and Quality under Loess Plateau Region**. Plants, 2022, 11. <https://doi.org/10.3390/plants11202801>

BROWN, M. B.; FORSYTHE, A. B. 1974. Robust tests for the equality of variances. J. Am. Stat. Assoc., 69: 364 – 367.

CHANG, G. J.; OH, Y.; GOLDSHLEGER, N.; SHOSHANY, M. **Biomass estimation of crops and natural shrubs by combining red-edge ratio with normalized difference vegetation index**. Journal of Applied Remote Sensing, 2022, 16. <https://doi.org/10.1117/1.JRS.16.014501>

CHEN, J.; GUO, J.; YANG, Z.; YANG, J.; DONG, H.; WANG, H.; WANG, Y.; ZHAN, F. **The Application of Fertilizer and AMF Promotes Growth and Reduces the Cadmium and Lead Contents of Ryegrass (*Lolium multiflorum* L.) in a Copper Mining Area**. Phytion-International Journal of Experimental Botany, 2023, 92. DOI: 10.32604/phyton.2022.023660

CHOI, M.; CHOI, N.; LEE, J.; LEE, S.; KIM, Y.; NA, C. **Effects of Italian Ryegrass (*Lolium multiflorum*) Cultivation for Green Manure and Forage on Subsequent Above- and**

Below-Ground Growth and Yield of Soybean (Glycine max). Agriculture, 2023, 13. <https://doi.org/10.3390/agriculture13102038>

FANG, P.; YAN, N.; WEI, P.; ZHAO, Y.; ZHANG, X. **Aboveground Biomass Mapping of Crops Supported by Improved CASA Model and Sentinel-2 Multispectral Imagery.** Remote Sens. 2021, 13. <https://doi.org/10.3390/rs13142755>

FIELD, A. *Descobrimos a estatística usando o SPSS, 2. ed. – Dados eletrônicos. – Porto Alegre: Artmed, 2009.*

FRAMPTON, W. J.; DASH, J.; WATMOUGH, G.; MILTON, E. J. **Evaluating the Capabilities of Sentinel-2 for Quantitative Estimation of Biophysical Variables in Vegetation.** ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 82. doi:10.1016/j.isprsjprs.2013.04.007

FRIEDLINGSTEIN, P.; O'SULLIVAN, M.; JONES, M. W.; ANDREW, R. M. **Global Carbon Budget 2020.** Earth Syst. Sci. Data, 2020, 12. <https://doi.org/10.5194/essd-12-3269-2020>, 2020.

GAMON, J. A.; PENUELAS, J.; FIELD, C. B. **A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency.** Remote Sensing of Environment, 1992, 41.

GARGIULO, J. I.; LYONS, N. A.; MASIA, F.; BEALE, P.; INSUA, J. R.; CORREA-LUNA, M.; GARCIA, S. C. **Comparison of Ground-Based, Unmanned Aerial Vehicles and Satellite Remote Sensing Technologies for Monitoring Pasture Biomass on Dairy Farms.** Remote Sens., 2023, 15. <https://doi.org/10.3390/rs15112752>

GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F. D. **Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data.** International Journal of Remote Sensing, 2019, 41. <https://doi.org/10.1080/01431161.2019.1697004>

GRAMINHO, L. A.; ROCHA, M. G.; PÖTTER, L.; ROSA, A. T. N.; SALVADOR, P. R.; AMARAL, L. G.; BERGOLI, T. L.; CADÓ, L. M. **Effect of herbage allowances on biomass flows in Italian ryegrass.** Ciência Rural, 2019, 49.

HUA, Y.; ZHAO, X. **Multi-Model Estimation of Forest Canopy Closure by Using Red Edge Bands Based on Sentinel-2 Images.** *Forests* 2021, 12, 1768. <https://doi.org/10.3390/f12121768>

IPCC - Intergovernmental Panel on Climate Change. **Good practice guidance for land use, land-use change and forestry.** IPCC National Greenhouse Gas Inventories Programme, UNEP, 2003. Disponível em: https://www.ipcc-nggip.iges.or.jp/public/gpگلulucf/gpگلulucf_contents.html

IPCC - Intergovernmental Panel on Climate Change. **IPCC Guidelines for National Greenhouse Gases Inventories, chapter 3.4 - Grassland.** 2006. Disponível em: https://www.ipcc-nggip.iges.or.jp/public/gpگلulucf/gpگلulucf_files/Chp3/Chp3_4_Grassland.pdf

JERONIMO, P., A.; HRABE, F.; KNOT, P.; KVASNOVSKY, M. Evaluation of Suitability of Grass Species for dry Conditions (Water Stress). *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 2014, 62. <http://dx.doi.org/10.11118/actaun201462050953>

KIM, M.; PENG, J.; SUNG, K. **Causality between climatic and soil factors on Italian ryegrass yield in paddy field via climate and soil big data.** *Journal of Animal Science and Technology*, 2019, 61. <https://doi.org/10.5187/jast.2019.61.6.324>

KEMESYTE, V.; STATKEVICIUTE, G.; NORKEVICIENE, E.; JASKUNE, K. **Italian Ryegrass as a Forage Crop for the Baltics: Opportunities and Challenges in Light of Climate Change.** *Plants* 2023, 12, 3841. <https://doi.org/10.3390/plants12223841>
KÖPPEN, W., 1936: **Das geographische System der Klimate.** KÖPPEN, W., R. GEIGER (Eds.): *Handbuch der Klimatologie.* Gebrüder Bornträger, Berlin, 1, 1–44, part C.

KOSTRZEWSKA, M.K.; JASTRZEBSKA, M.; TREDER, K.; WANIC, M. **Phosphorus in Spring Barley and Italian Rye-Grass Biomass as an Effect of Inter-Species Interactions under Water Deficit.** *Agriculture*, 2020, 10. <https://doi.org/10.3390/agriculture10080329>

KUMARI, S.; MAITI, S. K. **Reclamation of coalmine spoils with topsoil, grass, and legume: a case study from India.** *Environ Earth Sci*, 2019, 78. <https://doi.org/10.1007/s12665-019-8446-2>

LE MAIRE, G.; MARSDEN, C.; NOUVELLON, Y.; GRINAND, C.; HAKAMADA, R.; STAPE, J.; LACLAU, J. **MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass.** *Remote Sensing of Environment*, 2011, 115. <https://doi.org/10.1016/j.rse.2011.05.017>

LEVENE, H. **Robust tests for equality of variances.** In *Contributions to Probability and Statistics*, Edited by: Olkin, I. 278 – 292. Stanford: Stanford University Press. 1960

LI, C.; ZHOU, L.; XU, W. **Estimating Aboveground Biomass Using Sentinel-2 MSI Data and Ensemble Algorithms for Grassland in the Shengjin LakeWetland, China.** *Remote Sens.* 2021, 13. <https://doi.org/10.3390/rs13081595>

MAPABIOMAS. Projeto MapBiomass – Coleção 8.0 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Acessado em 14 de Agosto de 2024. Através do link: <https://brasil.mapbiomas.org/estatisticas/>

MUNYATI, C. **Detecting the distribution of grass aboveground biomass on a rangeland using Sentinel-2 MSI vegetation indices.** *Advances in Space Research*, 2022, 69. <https://doi.org/10.1016/j.asr.2021.10.048>

RADOSZ, L.; CHMURA, D.; PROSTANSKI, D.; WOZNIAK, G. **The Soil Respiration of Coal Mine Heaps' Novel Ecosystems in Relation to Biomass and Biotic Parameters.** *Energies*, 2023, 16. <https://doi.org/10.3390/en16207083>

RAHMAN, A.F.; GAMON, J.A.; FUENTES, D.A.; ROBERTS, D.; PRENTISS, D.; QIU, H. 2000. Modeling CO₂ flux of boreal forests using narrow-band indices from AVIRIS imagery. AVIRIS Workshop, JPL/NASA, Pasadena, Califórnia.

REN, H.; ZHOU, G.; ZHANG, X. **Estimation of green aboveground biomass of desert steppe in Inner Mongolia based on red-edge reflectance curve area method.** *Biosystems Engineering*, 2011, 109. <https://doi.org/10.1016/j.biosystemseng.2011.05.004>

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: PROCEEDINGS OS THIRD ERTS-1 SYMPOSIUM, n. 1, 1973, Washington, DC, p. 309-327.

SALMAN, A. K. D.; SOARES, J. P. G.; CANESIN, R. C. **Métodos de amostragem para avaliação quantitativa de pastagens**. Circular Técnica, 84. EMBRAPA, MAPA, 2006.

SANQUETTA, C.R. et al. **Inventários florestais: planejamento e execução**. Curitiba, 2014.

SCHMIDT, M. W. I.; TORN, M. S.; ABIVEN, S.; DITTMAR, T.; GUGGENBERGER, G.; JANSSENS, I. A.; KLEBER, M.; KOGEL-KNABNER, I.; LEHMANN, J.; MANNING, D. A. C.; NANNIPIERI, P.; RASSE, D. P.; WEINER, S.; TRUMBORE, S. E. **Persistence of soil organic matter as na ecosystem property**. Nature, 2011, 478. doi:10.1038/nature10386

SIBANDA, M.; MUTANGA, O.; ROUGET, M.; KUMAR, L. **Estimating Biomass of Native Grass Grown under Complex Management Treatments Using WorldView-3 Spectral Derivatives**. Remote Sens. 2017, 9. <https://doi.org/10.3390/rs9010055>

SILVA, S. C. P.; BAPTISTA, G. M. M. **Análises Espectrais da Vegetação com Dados Hyperion e sua Relação com a Concentração e o Fluxo de CO₂ em Diferentes Ambientes na Amazônia Brasileira**. Boletim de Ciências Geodésicas, 2015, 21.

SHARIFI, A.; FELEGARI, S. **Remotely sensed normalized difference red-edge index for rangeland biomass estimation**. Aircraft Engineering and Aerospace Technology, 2023, 95. <https://doi.org/10.1108/AEAT-07-2022-0199>

TERRER, C.; PHILLIPS, R. P.; HUNGATE, B. A. **A trade-off between plant and soil carbon storage under elevated CO₂**. Nature, 2021, 591. <https://doi.org/10.1038/s41586-021-03306-8>

THENKABAIL, P. S.; SMITH, R. B.; DE-PAUW, E. **Hyperspectral vegetation indices for determining agricultural crop characteristics**. Remote Sensing of Environment, 1999, 71.

VELOSO, G. A.; SILVA, J. R.; FERREIRA, M. E.; FERREIRA JR., L. G. **Biomassa Seca Estimada em Áreas de Pastagens com Dados de Sensoriamento Remoto: Estudo de caso na Bacia Hidrográfica do Rio Vermelho – Goiás**. Sociedade e Território, 2020, 32. <https://doi.org/10.21680/2177-8396.2020v32n2ID22641>

2.3.3 *Artigo 3: PAIM, B. L.; ALVES, R. C. M.; LIMA, B. D. BAYER, C.; CAUMO, M. CO₂ and CH₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining*

Journal of Soils and Sediments

CO₂ and CH₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining --Manuscript Draft--

Manuscript Number:	
Full Title:	CO ₂ and CH ₄ flux dynamics in pastoral systems in an area near thermoelectric plants and coal mining
Article Type:	Research Article
Section/Category:	Soils
Corresponding Author:	Bruna Lüdtké Paim Federal University of Rio Grande do Sul: Universidade Federal do Rio Grande do Sul BRAZIL
Corresponding Author Secondary Information:	
Corresponding Author's Institution:	Federal University of Rio Grande do Sul: Universidade Federal do Rio Grande do Sul
Corresponding Author's Secondary Institution:	
First Author:	Bruna Lüdtké Paim
First Author Secondary Information:	
Order of Authors:	Bruna Lüdtké Paim Rita de Cássia Marques Alves Bianca Dutra de Lima Cimelio Bayer Monique Caumo
Order of Authors Secondary Information:	
Funding Information:	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior MSc Bruna Lüdtké Paim
Abstract:	<p>This study aimed to evaluate carbon dioxide (CO₂) and methane (CH₄) emissions from the soil of different pasture systems impacted by thermoelectric projects and mining areas. Soil CO₂ and CH₄ fluxes were assessed in a region in southern Brazil, using manual static chambers over the course of two seasons, at three sampling points (Copelmi Farm - opposite the predominant wind; Mine - CRM - coal mine and the Ranch - UTE - next to the power plant, in the direction of the predominant wind). The point near the thermal power plant showed higher CO₂ emissions from the soil than the point in the mining area. CH₄ was consumed in the soil in most of the samples. In the sampling period with the highest rainfall accumulations, the soil had the highest percentages of soil moisture and therefore the lowest CH₄ consumption, while the opposite tendency occurred in the sampling period with the lowest rainfall accumulations. CO₂ showed a strong correlation with the soil variables humidity and temperature, being negative for humidity ($r = -0.84$) and positive for temperature ($r = 0.79$). CH₄ showed the best correlation with humidity ($r = 0.53$) and the lowest with temperature ($r = -0.33$), with humidity presenting the opposite sign to that presented by CO₂. Overall, the areas adjacent to thermal power plant and coal mining show the impact of these anthropogenic actions on greenhouse gas emissions and the relationship between meteorological variables.</p>
Suggested Reviewers:	Jéssica Pereira jessicaagro11@gmail.com Ana Paula Levandoski anapaula.levandoski@gmail.com

ABSTRACT

This study aimed to evaluate carbon dioxide (CO₂) and methane (CH₄) emissions from the soil of different pasture systems impacted by thermoelectric projects and mining areas. Soil CO₂ and CH₄ fluxes were assessed in a region in southern Brazil, using manual static chambers over the course of two seasons, at three sampling points (Copelmi Farm - opposite the predominant wind; Mine - CRM - coal mine and the Ranch – UTE - next to the power plant, in the direction of the predominant wind). The chemical and physical characterization of the soil was also evaluated, as well as the influence of meteorological variables. The point near the thermal power plant showed higher CO₂ emissions from the soil than the point in the mining area. CH₄ was consumed in the soil in most of the samples. In the sampling period with the highest rainfall accumulations, the soil had the highest percentages of soil moisture and therefore the lowest CH₄ consumption, while the opposite tendency occurred in the sampling period with the lowest rainfall accumulations. CO₂ showed a strong correlation with the soil variables humidity and temperature, being negative for humidity ($r = -0.84$) and positive for temperature ($r = 0.79$). CH₄ showed the best correlation with humidity ($r = 0.53$) and the lowest with temperature ($r = -0.33$), with humidity presenting the opposite sign to that presented by CO₂. Overall, the areas adjacent to thermal power plant and coal mining show the impact of these anthropogenic actions on greenhouse gas emissions and the relationship between meteorological variables.

Keywords: Soil. Carbon. Emission. Power plant. Mining.

1. INTRODUCTION

Climate change in general has greatly concerned the world's population as it warns of an increase in extreme weather events around the world. Due to the uncertainties concerning the future of the planet's climate, in 1988 the United Nations Environment Programme (UNEP) and the World Meteorological Organization (WMO) created the Intergovernmental Panel on Climate Change (IPCC). Through analysis of scientific information, the IPCC provides information on the potential environmental and socio-economic impacts of climate change (Santos et al. 2011). The scenarios established by the IPCC include low anthropogenic emissions (optimistic), attempted reductions but slow progress (realistic) and high emissions (pessimistic). These scenarios mainly take into account anthropogenic emissions of greenhouse gases and aerosols, as well as information on the type of land cover for their projections (Avila, 2007).

There are currently many projects and works developed and under development for agricultural and farming regions, as these are areas with the greatest environmental impact

(Barnard et al., 2020; Bezyk et al., 2021; Amadori et al., 2022; Rupngam et al., 2023). However, in Brazil there are other areas and biomes that, despite being relevant in the environmental context, are still little explored in studies related to the subject, such as areas impacted by thermoelectric projects.

The state of Rio Grande do Sul is the site of two types of biome: the Atlantic Forest, one of the largest tropical forests in the Americas, and the Pampa biome, the most representative in the state, occupying approximately 63% of the state's territory (Overbeck et al., 2022). Inside this biome, the Presidente Médici Thermoelectric Power Plant (Phase C) and the Pampa Sul Thermoelectric Power Plant are in operation, and new thermoelectric projects are still being licensed in the region. In regions under the influence of thermoelectric plants, there is great environmental concern due to the emission of fossil fuels and gases into the atmosphere. In general, these fossil fuel burnings generate greenhouse gas (GHG) emissions, principally carbon dioxide (CO₂) and methane (CH₄) (Paranaíba et al., 2018). Although many studies describe these greenhouse gas fluxes, there is a lack of approaches that integrate the different factors, assessing not only carbon (C) emissions to the atmosphere, but also other ecological processes, such as the incorporation of these gases into the soil. In order to integrate terrestrial (biosphere) and atmospheric fluxes, this study proposes to quantify the carbon emitted by the soil, both in areas impacted by coal mining and by thermal power plants. This approach aims to investigate the terrestrial carbon balance in order to study the dynamic atmosphere-biosphere processes in regions influenced by thermal power plants.

2. MATERIALS AND METHODS

2.1. STUDY AREA

The experiment was conducted in the municipality of Candiota, state of Rio Grande do Sul, southern Brazil (31°28' 36"S and 53°40'45"W) (Fig. 1). The region's biome is characterized as Pampa and, according to Alvares et al. (2013), the local climate is of the Cfa type: subtropical (Zone C), humid (f) and with hot summers (a), according to the criteria of the Köppen climate classification (1936). In this, the letter "f" indicates monthly rainfall distributed throughout the year, with no dry season; and the letter "a" refers to the mean temperature of the warmest month being greater than or equal to 22 °C and the mean temperature of the coldest month being between -3 and 18 °C. The soil at the site is classified as chernosolic Ebonic Artic Vertisol (Streck et al., 2018), shallow to deep loam, with a medium loamy texture.

The Candiota III - Phase C Thermoelectric Power Plant is in operation in the study area, burning coal from the Candiota Mine, administered by Companhia Riograndense de Mineração (CRM). Another plant operating in the region is the Pampa Sul Thermoelectric Plant, which generates energy by burning coal extracted from the Seival Mine.

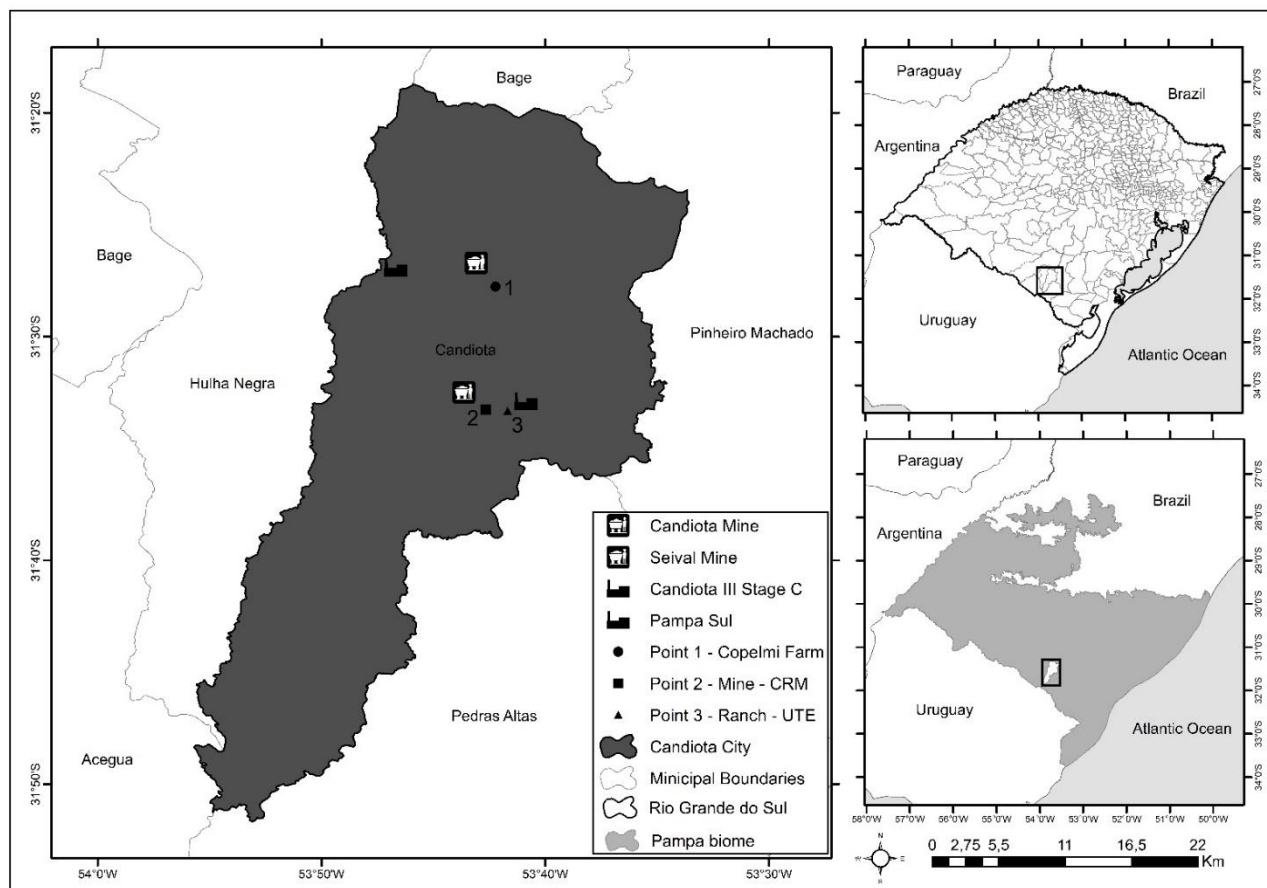


Fig. 1 Delimitation of the study area and pampa biome and location of the sampling points. Municipality of Candiota, RS.

2.2.FIELD EXPERIMENT AND SAMPLING

2.2.1. Soil selection, sample preparation and analysis

The composite soil samples were collected on October 14, 2022, in native field and planted pasture vegetation at Point 1 (Copelmi Farm) - opposite the predominant wind; Point 2 (Mine - CRM) - coal mine and Point 3 (Ranch - UTE) - near the power plant, in the direction of the predominant wind (Fig. 2), in the 0-10 cm (surface) and 10-20 cm (subsurface) depth layers, which were then kept refrigerated at approximately 4 °C. In the three defined sampling units (50 x 20 m), the area was walked randomly so that around 15 sub-samples could be collected.. The sub-samples were then mixed, following the methodology proposed by EMBRAPA SOLOS (1997). The material was stored in plastic bags until it was air-dried in an oven at 40 °C to a constant weight, buffered, passed through

a fine sieve with a mesh size of 2 mm to obtain the air-dried fine soil fraction, and ground on an agate grater, according to Fruett et al. (2022). Around 50 mg of each sample was subjected to dry combustion in a carbon analyzer (Flash 2000 IRMS, Thermo Fisher Scientific) to determine total organic carbon (TOC).




Fig. 2 Vegetation composition of the sampling points (a) Point 1 (Copelmi Farm), (b) Point 2 (CRM - Mine) and (c) Point 3 (Ranch - UTE).

2.2.2. Measurements of carbon dioxide and methane emissions from the soil

CO₂ and CH₄ fluxes in the soil were assessed in two air sampling sessions from October 11 to 15, 2022, in spring, and from July 23 to 29, 2023, in winter. The air samples were collected using the closed chamber method (Costa et al. 2006), with PVC chambers 20 cm high and 25 cm in diameter, implanted in metal rings, also 25 cm in diameter, previously inserted 5 cm deep into the soil. At the top of each base, a water-filled slit prevented the exchange of gases between the inside and outside of the chamber. The bases remained in the ground throughout the experiment. The chambers were equipped with a thermometer and a 12 V ventilator to homogenize the internal air mass (Fig. 3).



Fig. 3 Static chambers used in the soil gas sampling experiment. (a) Chamber installed with the metal base attached to the ground, with a digital thermometer to measure the internal temperature of the chamber, and a digital thermometer inserted into the ground to measure the soil temperature, a battery to power the internal fan and a three-way system to collect the gas using a syringe. (b) Four chambers installed at Point 3 - Ranch - UTE.

Four metal rings were installed in each plot. A circumscribed rectangle measuring 10 x 25 m was marked out for each metal ring. Each air sampling session began at 09:00, when the chamber was positioned on the metal ring. An air sample was collected with a 20 mL polypropylene syringe from the top of the chamber at 0, 15, 30 and 45 min after implantation.

The air sample in the syringe was transferred to a pre-evacuated 14 mL glass vial (Exetainer) and stored at low temperatures until analysis (approximately 4 °C). CO₂ and CH₄ concentrations were determined by gas chromatography using a GC Trace 1310 (Thermo Scientific), equipped with an electronic capture detector for CO₂ and a flame ionization detector for CH₄. As quality control for the GC analysis, a standard gas concentration curve was used, with four standard concentrations of CO₂ and CH₄ (standard mixtures supplied by Praxair-White Martins), and for every 20 samples, a standard sample was also analyzed to check the accuracy of the measurements.

The CO₂ and CH₄ fluxes in the soil were estimated from the inclination of the linear model fitted to describe the increase in gas concentration during the 45-minute implantation. The internal temperature, atmospheric pressure (assumed to be 1 atm), chamber volume and the area of soil delimited by the metal ring were also taken into account. The accumulated CO₂ and CH₄ emissions for each of the sampling points were transformed into equivalent carbon (EC).

On each gas collection date, soil samples 0-10 cm deep were collected with an Holland auger, in two repetitions for each chamber, to determine soil moisture, with temperature at a depth of 10 cm also monitored using a digital thermometer, previously inserted near each gas chamber in each sub-plot. In addition, meteorological information (precipitation, air temperature and daily wind speed and direction) throughout the experimental period was obtained from an automatic weather station located less than 40 km from the experimental area (INMET station A827).

3. RESULTS AND DISCUSSION

3.1. Soil chemical and physical characterization

Table 1 shows the total organic carbon content of the soils (TOC). TOC values ranged from 1.06% (P1 - 0.10-0.20 m) to 2.28% (P2 - 0.0-0.10 m) (Table 1). The soil from the mining area (Point 2) showed higher levels of carbon than the soils sampled at the other points evaluated, as well as greater moisture in the surface layer (23.63 %). This accumulation of carbon is also due to the continuous carbonization process to which coal is naturally exposed, that makes it progressively enriched in carbon (Silva et al., 2010).

Table 1. Total organic carbon content (%) at the different soil depths at the three sampling points.

Sample Unit	Soil depth	Carbon (%)	Moisture (%)
-------------	------------	------------	--------------

Point 1	0-0.10	1.34	13.34
(Copelmi Farm)			
Cultivated pasture	0.10-0.20	1.06	14.50
Point 2	0-0.10	2.28	23.63
(Mine - CRM)			
Cultivated pasture	0.10-0.20	1.66	22.29
Point 3	0-0.10	1.36	11.64
(Ranch - UTE)			
Native field	0.10-0.20	1.14	8.75

Carbon allocation by vegetation contributes to soil carbon dynamics (Schmidt et al., 2011). Considering that the covering crop at Point 1 was more dominantly *Lolium Multiflorum Lam.* (Italian ryegrass) and *Lolium Perene L.* (perennial ryegrass), at Point 2 – Mine - CRM was also planted pasture with more dominance of *Urochloa Decumbens* Stapf. (brachiaria grass), and at Point 3 - Ranch - UTE, natural pasture, the interaction between the vegetation and the soil promotes different processes in the various soil layers (surface and subsurface).

3.2 CO₂ and CH₄ fluxes in the soil

Soil CO₂ fluxes presented different behavior in each of the sampling units. At Point 1 (Copelmi Farm), where ryegrass is more dominant and the soil has a lower percentage of carbon stored at different depths (Table 1), the CO₂ fluxes from the soil to the atmosphere had a higher peak on the day after the rain (2022/10/12), when the soil was more moist (Fig. 4). When there is little moisture in the soil there is less CO₂ emission, and according to Fang and Moncrieff (1999), the metabolic activity of microorganisms and roots decreases due to the low availability of water.

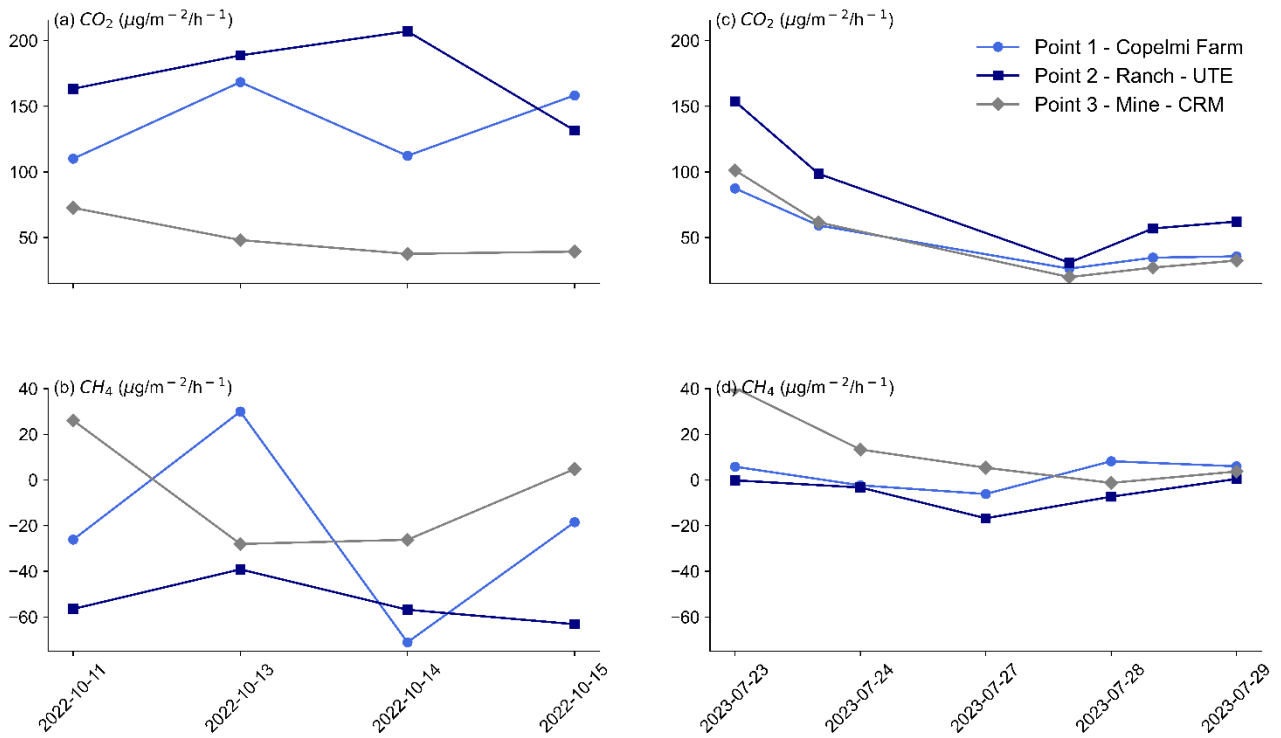


Fig. 4 (a) Carbon dioxide fluxes and (b) methane fluxes from the three sampling points during spring; (c) Carbon dioxide fluxes and (d) methane fluxes from the three sampling points during winter

The opposite is observed in winter, when after the precipitation there was a reduction in CO_2 fluxes in the soil, possibly due to the intensity of the rainfall. In spring, the rainfall episode amounted to a daily accumulation of 2.5 mm (Fig. 5), while in winter the daily accumulation was over 20 mm (Fig. 6). More intense rainfall in a soil that is saturated causes an increase in surface runoff, preventing water from reaching deeper layers of the soil (Pruski et al., 2004; Santos et al., 2010).

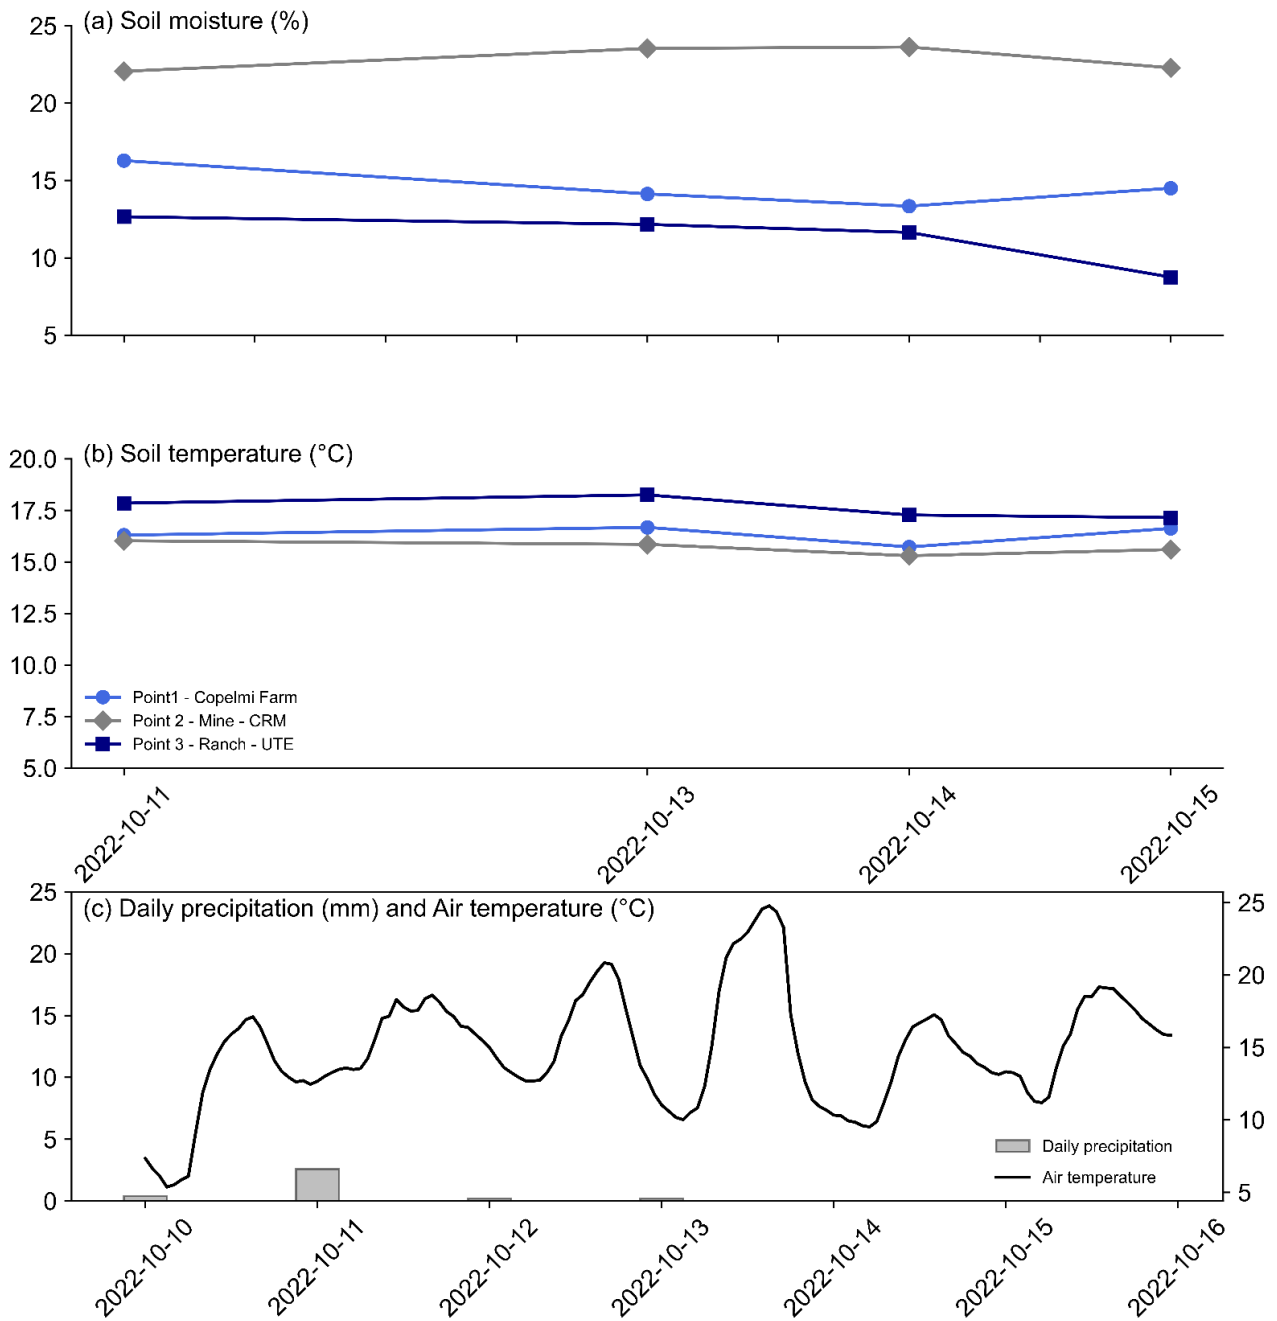


Fig. 5 (a) Moisture and (b) temperature in the top 5 cm of soil at the three sampling points and (c) daily precipitation and average daily air temperature during the spring sampling period

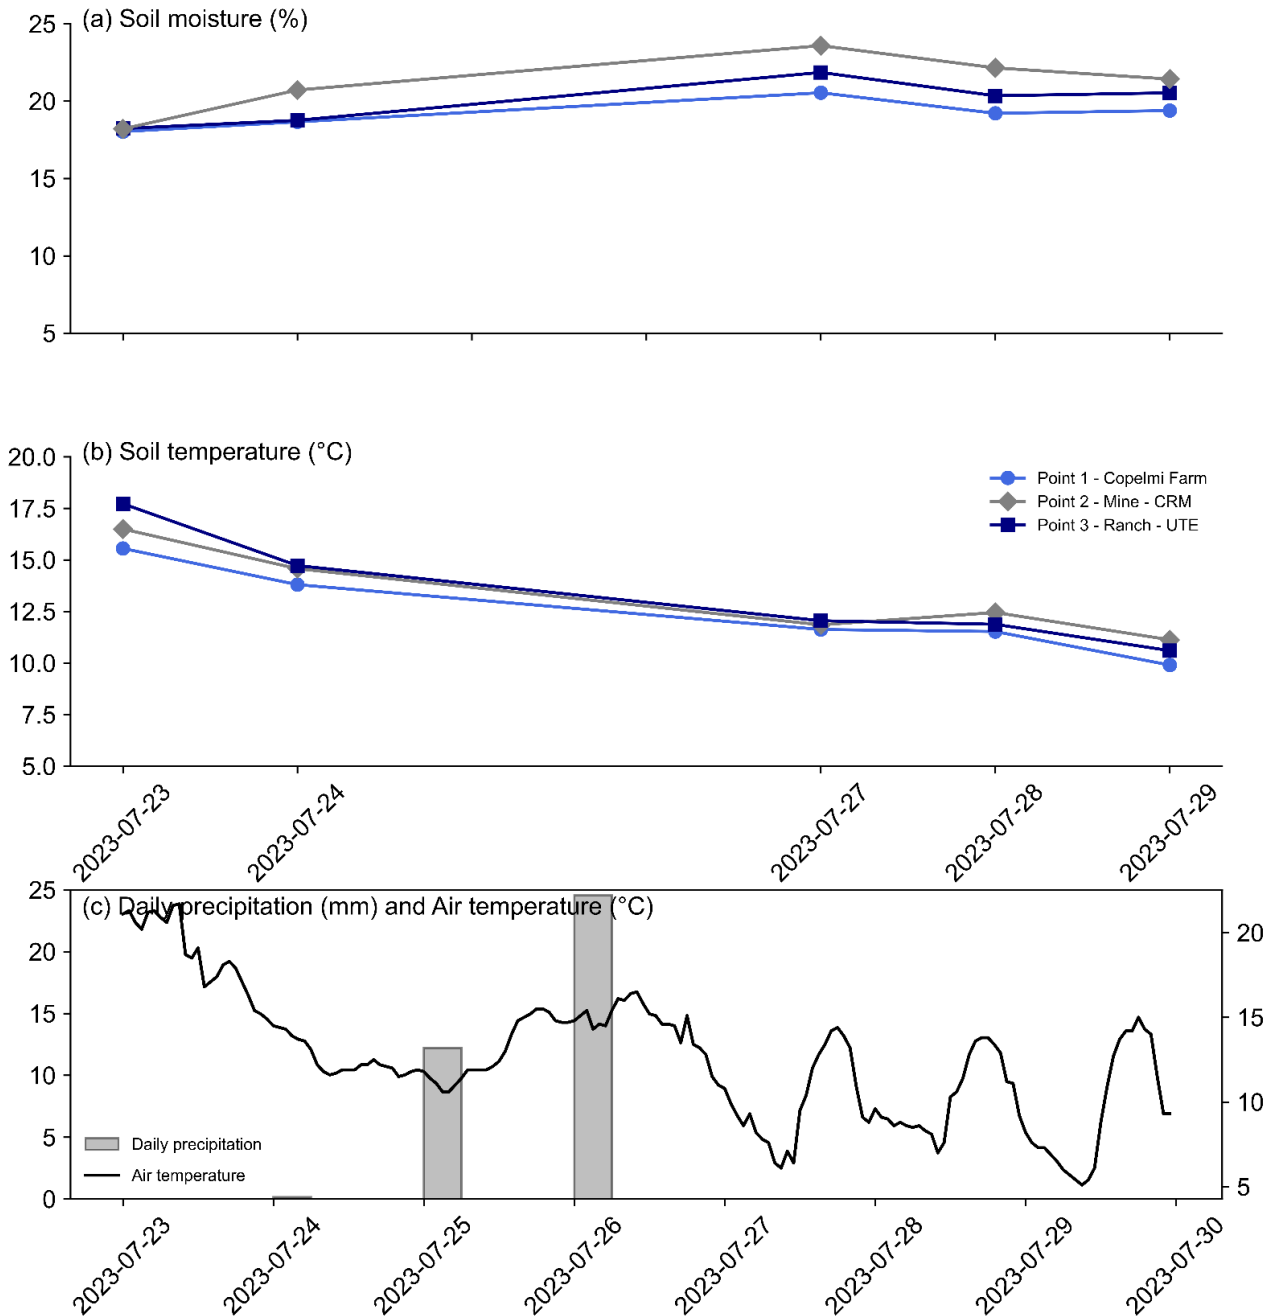


Fig. 6 (a) Moisture and (b) temperature in the top 5 cm of soil at the three sampling points and (c) daily precipitation and average daily air temperature during the winter sampling period

As soil moisture increases, the decrease in CO₂ emissions from the soil may also be associated with factors limiting the heterotrophic respiration of soil microorganisms. When the soil is moist, CO₂ production is inhibited by the lack of available oxygen, since the macropores in the soil are filled with water (Veeck et al., 2018). Pearson's correlation coefficient (r) shows that the soil moisture variable has a high negative correlation with CO₂ (-0.84).

As can be seen, in contrast to the spring samplings, the winter samplings took place during a wetter period, with accumulated rainfall around 38 mm higher than previously recorded. This volume of precipitation possibly increased soil moisture to the highest level observed during sampling, from 18 to 24 % (Fig. 6). Thus, the higher cumulative CH₄ emissions that occurred during this same winter period are attributed to these humidity conditions, due to water saturation providing anaerobic conditions (absence of O₂), favorable to methane production (Saggar et al., 2008; Piva et al., 2014). For CH₄, the correlation is positive ($r = 0.53$), differently to the behavior shown by CO₂.

Overall, the temporal variation in soil moisture, affected by precipitation, was a determining factor in gas fluxes. Significant increases in greenhouse gas emissions, especially CH₄, can intensify extreme climate events (Nunes et al., 2023). At the three sampling points, the highest CH₄ emissions and the lowest CO₂ emissions occurred in the period with the highest rainfall and soil moisture, while the opposite occurred in the period with the lowest accumulated rainfall, indicating that the seasonality of rainfall affected GHG emissions. Amadori et al. (2022) reported similar results, also observing the influence of rainfall seasonality on N₂O and CH₄ emissions in integrated agricultural systems (crop, livestock and forest). They observed that in the rainy season there were higher N₂O emissions and lower CH₄ consumption by the soil.

Soil temperature also contributes to GHG emissions, showing a high correlation with CO₂ ($r = 0.79$) but a low correlation with CH₄ ($r = -0.33$), indicating that fluctuations in CH₄ fluxes are more influenced by soil moisture. Higher soil temperatures favor an increase in substrates (acetic acid and hydrogen, for example) that serve as support for organism, consequently increasing methanogenesis (emission of CH₄ into the atmosphere) (Mosier et al., 2004). The methane flux records observed in the three sample areas in winter are on the same date (Fig. 3 d) and on the day when the highest soil temperatures were recorded, 16 °C at Point 1 – Copelmi Farm, 17 °C at Point 2 – Mine - CRM and 18 °C at Point 3 – Ranch - UTE. The emission fluxes of both CH₄ and CO₂ observed in winter are sensitive to variations in soil temperature, soil moisture and precipitation, suggesting that these three variables are the main factors causing emissions of these gases into the soil.

This same influence cannot be observed in the spring, possibly because the variables linked to the soil (temperature and moisture), remained practically constant during the sampling period (Fig. 6 a, b) and rainfall was not as significant compared to the winter (Fig. 5 c and Fig. 6 c). However, in this case the type of soil cover may have affected the quality of the soil structure. At the Ranch - UTE point (3) the cover was natural pasture while at the Mine - CRM point (2) it was planted pasture (recovery area). According to several studies

(Mosier et al., 1991; Castaldi et al., 2007; Cai et al., 2017) pasture soils are typically a major sink for atmospheric CH₄, since CH₄ oxidation prevails in these soils.

Accumulated CO₂ emissions (Table 2) in both seasons were highest at point 3, Ranch - UTE, and lowest in the mining area (Point 2: CRM), while CH₄ emissions showed the opposite result, with the highest emissions in the mining area and the lowest at the point nearest the thermal power plant. In spring, methane absorption was lowest in the mining area (-1.22 kg EC -C ha⁻¹) and highest at the point near the power plant (-8.38 kg EC -C ha⁻¹). The proximity to the thermal power plant may have caused the highest CO₂ emissions at Point 3 (1.02 kg EC -C ha⁻¹), since this point is located in the predominant wind direction, and the deposition of the plume emitted by the thermal power plant chimney occurs in this sampling area. When observing the relationship with the percentage of soil moisture in each area, the accumulated CH₄ (negative values, absorption by the soil, positive values, emission) was possibly promoted by this variable, which in the mining area was greater than 22% in both periods. In soils, higher humidity restricts oxygen, and in this condition methanotrophic bacteria reduce organic compounds to CH₄ (Garcia et al., 2000).

Table 2. Cumulative seasonal emissions of carbon dioxide and methane at the three sampling points during spring and winter sampling. The cumulative values are presented in equivalent carbon.

Cumulative seasonal emission (spring – 2022/10/11 to 2022/10/15) (kg EC -C ha ⁻¹)		
Sample Unit	CH ₄	CO ₂
Point 1 (Copelmi Farm)	-2.07	0.87
Point 2 (Mine - CRM)	-1.22	0.30
Point 3 (Ranch – UTE)	-8.38	1.02
Cumulative seasonal emission (winter – 2023/07/23 to 2023/07/29) (kg EC -C ha ⁻¹)		
Point 1 (Copelmi Farm)	0.42	0.36
Point 2 (Mine - CRM)	2.26	0.36
Point 3 (Ranch – UTE)	-1.01	0.60

This methane sink behavior in pasture soils has also been reported in other studies, such as Godoi et al. (2016), who when evaluating the effect of legume afforestation in native grasslands on soil greenhouse gas flows, identified a CH₄ consumption behavior by the soil, -1.75 kg C-CH₄ ha⁻¹ year⁻¹ in native grassland, a behavior also identified by Amadori et al.

(2022) when assessing soil methane emissions from integrated agricultural systems, where accumulated consumption varied between -1.82 and -0.87 kg CH₄ -C ha⁻¹ year⁻¹.

The cumulative CO₂ emission values observed in this study were relatively low in the sampling periods conducted, but the higher cumulative emission obtained at Point 3 (Ranch - UTE) corroborates recent work by Holland et al. (2024), who investigated the effects of management practices and soil preparation in a pasture system and found cumulative CO₂ values between 2019 and 2021 ranging from 2.89 (2019) to 10.58 (2010) kg CO₂ ha⁻¹, with the value observed in 2019 being close to that observed in this study (1.02 kg EC -C ha⁻¹).

4. CONCLUSIONS

The soil around the mining area is heavily devastated, which results in the destruction of microbial activity that has a strong influence on soil carbon fluxes. The proximity of the thermal power plant also affects these flows, especially in the areas receiving the dispersion plume. Although the accumulated emission of methane in spring showed an absorption behavior in the different sample areas, being lower in the mining area and higher at the point near the thermoelectric plant, there was a higher emission of carbon dioxide into the atmosphere at the second point and a lower emission at the mining area. At all the sampling points, carbon dioxide and methane emissions occurred in the samples after precipitation events and with higher soil moisture, while the opposite trend occurred on days with lower soil moisture, indicating that the seasonality of precipitation was also a factor affecting emissions of this greenhouse gas into the atmosphere.

ACKNOWLEDGMENTS

We thank was supported by The Coordination for the Improvement of Higher Education Personnel (CAPES).

REFERÊNCIAS

Alvares C A et al (2013) Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift* 22: 711-728. DOI: 10.1127/0941-2948/2013/0507

Amadori C et al (2022) Nitrous oxide and methane emissions from soil under integrated farming systems in southern Brazil. *Science of the Total Environment* 828. <http://dx.doi.org/10.1016/j.scitotenv.2022.154555>

Avila A M H (2007) Uma síntese do quarto relatório do IPCC. *Revista Multiciência* 8.

Barnard R L, Blazewicz S J, Firestone M K (2020) Rewetting of soil: Revisiting the origin of soil CO₂ emissions. *Soil Biology and Biochemistry* 147. <https://doi.org/10.1016/j.soilbio.2020.107819>

Bezyk Y, Oshurok D, Dorodnikov M, Sówka I (2021) Evaluation of the CALPUFF model performance for the estimation of the urban ecosystem CO₂ flux. *Atmospheric Pollution Research* 12: 260-277. <https://doi.org/10.1016/j.apr.2020.12.013>

Boldrini I et al (2010) *Bioma Pampa: Diversidade Florística e Fisionômica*. Porto Alegre, Brazil

Cai Y, Chang S X, Cheng Y (2017) Greenhouse gas emissions from excreta patches of grazing animals and their mitigation strategies. *Earth-Science Reviews* 171: 44-57. <https://doi.org/10.1016/j.earscirev.2017.05.013>

Castaldi S et al (2007) The methane sink associated to soils of natural and agricultural ecosystems in Italy. *Chemosphere* 66: 723-729. <https://doi.org/10.1016/j.chemosphere.2006.07.089>

Costa F S, Gomes J, Bayer C, Mielniczuk J (2006) Métodos para avaliação das emissões de gases do efeito estufa no sistema solo-atmosfera. *Ciência do Solo* 36. <https://doi.org/10.1590/S0103-84782006000200056>

Dijkstra F A, Augustine D J, Brewer P, Von Fischer J C (2012) Nitrogen cycling and water pulses in semiarid grasslands: are microbial and plant processes temporally asynchronous?. *Oecologia* 170: 799-808. <https://doi.org/10.1007/s00442-012-2336-6>

Donagemma G K (2011) *Manual de métodos de análise de solo*. Embrapa Solos. <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/990374/manual-de-metodos-de-analise-de-solo>. Accessed 10 September 2024

Fang C, Moncrieff J (1999) A model for soil CO₂ production and transport 1: Model development. *Agricultural and Forest Meteorology* 95: 225-236. [https://doi.org/10.1016/S0168-1923\(99\)00036-2](https://doi.org/10.1016/S0168-1923(99)00036-2)

Fruett T et al (2022) Selectivity of soil constituents by termites in the construction of Brazilian termite mounds. *Scientia Agricola* 80. <https://doi.org/10.1590/1678-992X-2022-0147>

Garcia J, Patel B K C, Olliver B (2000) Taxonomic, Phylogenetic, and Ecological Diversity of Methanogenic Archaea. *Anaerobe* 6: 205-226. <https://doi.org/10.1006/anae.2000.0345>

Holland J E et al (2024) Effects of nutrient fertilization and soil tillage on soil CO₂ emissions in a long-term grassland experiment. *Soil & Tillage Research* 244. <https://doi.org/10.1016/j.still.2024.106232>

Intergovernmental Panel on Climate Change. 2006. IPCC Guidelines for National Greenhouse Gases Inventories, chapter 3.4 - Grassland. Kanagawa, Japan: Institute for Global Environmental Strategies. <https://www.ipcc-nggip.iges.or.jp/public/2006gl/vol2.html>. Accessed 10 September 2024

Kuo S, Sainju U M, Jellum E J (1997) Winter Cover Crop Effects on Soil Organic Carbon and Carbohydrate in Soil. *Soil Science Society of America Journal* 61: 145-152. <https://doi.org/10.2136/sssaj1997.03615995006100010022x>

Mosier A et al (1991) Methane and nitrous oxide fluxes in native, fertilized and cultivated grasslands. *Nature* 350: 330-332. <https://doi.org/10.1038/350330a0>

Mosier A et al (2004) Methane and Nitrogen Oxide Fluxes in Tropical Agricultural Soils: Sources, Sinks and Mechanisms. *Environment, Development and Sustainability* 6: 11-49. <https://doi.org/10.1023/B:ENVI.0000003627.43162.ae>

Nunes R S G et al (2023) Mitigation of ammonia and greenhouse gases emissions from urea coated with oil shale residues in a silvopastoral system. *Journal of Environmental Management* 326. <https://doi.org/10.1016/j.jenvman.2022.116779>.

Overbeck G E et al (2022) Placing Brazil's grasslands and savannas on the map of science and conservation. *Perspectives in Plant Ecology, Evolution and Systematics* 56. <https://doi.org/10.1016/j.ppees.2022.125687>

Paranaíba J R et al (2018) Spatially Resolved Measurements of CO₂ and CH₄ Concentration and Gas-Exchange Velocity Highly Influence Carbon-Emission Estimates of Reservoirs. *Environmental Science & Technology* 52. <https://doi.org/10.1021/acs.est.7b05138>

Piva J T et al (2014) Soil gaseous N₂O and CH₄ emissions and carbon pool due to integrated crop-livestock in a subtropical Ferralsol. *Agriculture, Ecosystems and Environment* 190: 87-93. <https://doi.org/10.1016/j.agee.2013.09.008>

Pruski, F. F.; Brandão, V. S.; Silva, D. D. Escoamento superficial. Viçosa: UFV, 2004. 87p.

Rupngam T, Messiga A J, Karam A (2023) Soil enzyme activities in heavily manured and waterlogged soil cultivated with ryegrass (*Lolium multiflorum*). *Canadian Journal of Soil Science* 104. <https://doi.org/10.1139/cjss-2023-0097>

Saggar S, Tate K R, Giltrap D L, Singh J (2008) Soil-atmosphere exchange of nitrous oxide and methane in New Zealand terrestrial ecosystems and their mitigation options: a review. *Plant Soil* 309: 25-42. <https://doi.org/10.1007/s11104-007-9421-3>

Santos G G et al (2010) Chuvas intensas relacionadas à erosão hídrica. *Revista Brasileira de Engenharia Agrícola e Ambiental* 14. <https://doi.org/10.1590/S1415-43662010000200001>

Santos R S et al (2011) Avaliação da relação seca/produtividade agrícola em cenário de mudanças climáticas. *Revista Brasileira de Meteorologia* 26. <https://doi.org/10.1590/S0102-77862011000200014>

Schmidt M, Torn M, Abiven S. et al (2011) Persistence of soil organic matter as an ecosystem property. *Nature* 478: 49-56. <https://doi.org/10.1038/nature10386>

Silva R et al (2010) Monitoring light hydrocarbons in Brazilian coal mines and in confined coal samples. *International Journal of Coal Geology* 84. <https://doi.org/10.1016/j.coal.2010.09.005>

Streck, Edemar Valdir et al.; Flores, Carlos Alberto; Schneider, Paulo (Eds.) Solos do Rio Grande do Sul. 3. ed., rev. e ampl. Porto Alegre: Emater/RS-Ascar, 2018. 252 p. il. color. ISBN 978-85-98842-20-2.

Veeck G P et al (2018) Preliminary analysis of the relationship between soil and CO₂ emissions from the ecosystem in an agroecosystem in southern Brazil. *Ciência e Natura* 40. <https://doi.org/10.5902/2179460X30897>

3 CONCLUSÕES

Os resultados demonstram que a integração de técnicas de sensoriamento remoto e geoprocessamento para estudar os dinâmicos processos atmosfera-biosfera sobre regiões influenciadas por empreendimentos termelétricos e exploração de carvão mineral a céu aberto, possuem grande potencial. A escassez de estudos desenvolvidos e aplicados a áreas impactadas por essas atividades motivou a utilização dessas técnicas e a busca por compreender a partir de amostras reais o impacto delas nas áreas de entorno.

Os resultados da classificação, com o uso de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) e de técnicas de segmentação de imagens, mostrou-se eficiente. Devido à extensão agrícola da área de estudo ser predominante e as áreas de mineração e infraestrutura urbana serem menores no processamento das classes, e pela semelhança das respostas espectrais dos alvos, esta última, apresentou menor acurácia. O presente trabalho também apresentou um estudo sobre a distribuição temporal e espacial das concentrações de carbono na área de estudo. Os resultados encontrados apontaram que a distribuição espacial de XCH_4 tem relação com a distribuição de atividades agrícolas e de produção de energia. O crescimento e o decréscimo anual e a amplitude de XCH_4 e o índice espectral CO_2Flux , respectivamente, variam em função das diferentes regiões indicando a dependência entre as variáveis e as atividades antrópicas.

Os resultados das variáveis biofísicas coletadas no campo mostraram que as variações de biomassa e carbono foram diferentes nos locais de amostragem, possivelmente devido ao manejo do solo e da vegetação em cada local, já que diferentes atividades humanas têm impacto sobre o solo e a vegetação. Verificou-se que não há diferença estatisticamente significativa entre as médias sazonais das duas variáveis analisadas. Esse estudo também apresentou um modelo para estimar as taxas de incorporação de biomassa e carbono, confirmando estudos anteriores de que os dados de sensoriamento remoto podem ser usados em estimativas de biomassa e carbono para pastagens.

Por meio destas abordagens para quantificar o carbono emitido pelo solo, foi possível identificar que a estrutura do solo ao redor da área de mineração é fortemente devastada, o que leva à destruição da atividade microbiana que exerce forte influência nos fluxos de carbono do solo. A proximidade com a termelétrica também afeta esses fluxos, principalmente nas áreas receptoras da pluma de dispersão. Em todos os pontos amostrais as emissões de dióxido de carbono e de metano ocorram nas amostragens posteriores a

eventos de precipitação e maior umidade no solo, enquanto a tendência oposta ocorreu nos dias de menor umidade do solo, indicando que a sazonalidade da precipitação também foi um fator que afetou as emissões desse gás de efeito estufa emitidos para a atmosfera.

Esta pesquisa destaca a importância do controle e do manejo da vegetação e do solo em áreas afetadas por projetos termelétricos e mineração a céu aberto para apoiar o desenvolvimento de medidas de recuperação de áreas degradadas com o objetivo de mitigar os impactos ambientais.

4 CONSIDERAÇÕES FINAIS

Os métodos de amostragem utilizados nesta tese apresentaram algumas limitações. Identificou-se que períodos de amostragem de fluxos no solo mais longos, pelo método de câmaras estáticas seria de suma importância para compreender melhor a dinâmica dos fluxos de carbono, visto que para estabelecer conexões mais significativas nos dados foi estatisticamente desafiador. A maior robustez do conjunto de dados pode definir a coerência dos resultados e justificar a correlação das variáveis físicas do solo e meteorológicas com os fluxos de carbono do solo.

A limitação de períodos de amostragem mais longos se estende também as amostras de vegetação, visto que uma maior quantidade de amostras de tecido vegetal seria importante para a validação do modelo de estimativa de biomassa e carbono gerado nesta tese. A validação de um modelo atesta a qualidade e a sua conformidade com os dados reais, por exemplo, para realizar a validação é necessária uma quantidade significativa de dados, para que parte deles seja utilizada para calibração e outra para validação.

O monitoramento atmosférico dos fluxos de carbono por sensores de alta frequência para um melhor balanço do carbono entre a superfície e a atmosfera também se observou importante. Após a conclusão das análises dos resultados, percebeu-se que a metodologia empregada para identificação dos fluxos de carbono no solo limitou a compreensão dos dinâmicos processos desses fluxos entre a superfície e a atmosfera.

Apesar das limitações apresentadas, a presente tese apresenta uma metodologia capaz de avaliar os processos de incorporação de carbono e biomassa por áreas campestres nas adjacências de áreas diretamente impactadas pela exploração e combustão de carvão mineral, e traz resultados relevantes quanto as emissões de carbono no solo nessas regiões.

FINANCIAMENTO

A produção científica desta tese foi financiada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), através de concessão de bolsa pelo Programa de Demanda Social.

REFERÊNCIAS

- ALMEIDA, Julio Roberto da Rocha; ROCHA, Karla da Silva. Aplicação dos índices de vegetação NDVI, PRI, e CO₂Flux na caracterização da cobertura vegetativa da área de proteção ambiental Raimundo Irineu Serra. *In: 7º SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL*, 2048, 2018, Jardim. **Anais [...]**. Brasília: INPE, 2018. p. 985-994.
- ALVARES, C.A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. DOI: 10.1127/0941-2948/2013/0507
- AMADORI, C. *et al.* Nitrous oxide and methane emissions from soil under integrated farming systems in southern Brazil. **Science of the Total Environment**, v. 828, 2022. <http://dx.doi.org/10.1016/j.scitotenv.2022.154555>
- AVILA, A. M. H. Uma síntese do quarto relatório do IPCC. **Revista Multiciência**, v. 8, p. 163-168, 2007.
- AYDIN, G.; KARAKURT, I.; AYDINER, K. Analysis and Mitigation Opportunities of Methane Emissions from the Energy Sector. **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, v. 34, n. 11, p. 967–982, 2012.
- AZUERO-PEDRAZA, C. G.; THOMAS, V. M. Incorporating biodiversity impacts in land use decisions. **Ecological Modelling**, v. 497, 2024. <https://doi.org/10.1016/j.ecolmodel.2024.110852>
- APITULEY, A. *et al.* Sentinel-5 precursor/TROPOMI Level 2 Product User Manual Methane. Royal Netherlands Meteorological Institute. 2021. Disponível: <https://sentinel.esa.int/documents/247904/2474726/Sentinel-5P-Level-2-Product-User-Manual-Methane.pdf/1808f165-0486-4840-ac1d-06194238fa96>. Acesso: 23 out. 2023.
- BAKER, D. J. *et al.* Achieving forest carbon information with higher certainty: A five-part plan. **Environmental Science and Policy**, v. 13, p. 249-260, 2010.
- BAPTISTA, Gustavo Macedo De Mello. Validação da modelagem de sequestro de carbono para ambientes tropicais de cerrado, por meio de dados AVIRIS e HYPERION. *In: XI SBSR*, 2003, Belo Horizonte. **Anais [...]**. São José dos Campos: INPE, 2003. p. 1037-1044.
- BORBA, Roberto Ferrari. Carvão Mineral. *In: BORBA, R. F. Balanço Mineral Brasileiro*. DNPM. 2001. p. 1-19.
- CGTEE - Companhia de Geração e Transmissão de Energia Elétrica do Sul do Brasil. Nosso negócio: Geração. Disponível em: <https://www.cgteletrosul.com.br/nosso-negocio/geracao/candiota>. Acesso em: 13 set. 2024..
- CHEN, Y. *et al.* Transmission Electron Microscopy Investigation of Ultrafine Coal Fly Ash Particles. **Environ. Sci. Technol.**, v. 39, n. 4, p. 1144–1151, 2005.
- COSTA, F. S. *et al.* Métodos para avaliação das emissões de gases do efeito estufa no sistema solo-atmosfera. **Cienc. Rural**, v. 36, p. 693–700, 2006.

COSTA, F. S. *et al.* Variação diária da emissão de metano em solo cultivado com arroz irrigado no Sul do Brasil. **Ciênc. Rural**, v. 38, 2008. <https://doi.org/10.1590/S0103-84782008000700041>

CRM - Companhia de Riograndense de Mineração. Atuação: Minas. Disponível em: <https://www.crm.rs.gov.br/minas>. Acesso em: 03 set. 2024.

DAVID, H. C. *et al.* The tropical biomass & carbon project—An application for forest biomass and carbon estimates. **Ecol. Model.**, v. 472, p. 110067, 2022.

DENMEAD, O. T.; RAUPACH, M. R. Methods for Measuring Atmospheric Gas Transport in Agricultural and Forest Systems. Em: **Agricultural Ecosystem Effects on Trace Gases and Global Climate Change**. [S.l.] John Wiley & Sons, Ltd, 1993. p. 19–43.

DONG, J. *et al.* Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and sinks. **Remote Sensing of Environment**, v. 84, p. 393-410, 2003.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Centro Nacional de Pesquisas de Solos. Manual de métodos de análise de solo. 2. ed. Rio de Janeiro: EMBRAPA-CNPQ, 1997. 212p.

ESPITIA-PÉREZ, Lyda. **Efeitos Biológicos do Material Particulado Gerado em Sistemas de Mineração de Carvão a Céu Aberto em Populações Humanas com Exposição Ambiental**. 2016. Tese (Doutorado em Biologia Celular e Molecular) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

FAWCETT, D. *et al.* Declining Amazon biomass due to deforestation and subsequent degradation losses exceeding gains. **Glob Change Biol**, v. 29, n. 4, p. 1106–1118, 2023.

FIX, A. *et al.* CoMet: an airborne mission to simultaneously measure CO₂ and CH₄ using lidar, passive remote sensing, and in-situ techniques. **EPJ Web Conf**, v. 176, p. 02003, 2018.

FRANKENBERG, C. *et al.* The Orbiting Carbon Observatory (OCO-2): spectrometer performance evaluation using pre-launch direct sun measurements. **Atmos Meas Tech**, v. 8, n. 1, p. 301–313, 2015.

FRUETT, T. *et al.* Selectivity of soil constituents by termites in the construction of Brazilian termite mounds. **Scientia Agricola**, v. 80, 2023. <https://doi.org/10.1590/1678-992X-2022-0147>

GAMON, J. A.; PENUELAS, J.; FIELD, C. B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**. v.41, p.35-44, 1992.

GOMES, A. J. P.; CRUZ, P. R.; BORGES, L. P. Recursos Minerais Energéticos: Carvão e Urânio. In: BIZZI, L. A.; SCHOBENHAUS, C.; VIDOTTI, R. M.; CONÇALVES, J. H. **Geologia, Tectônica e Recursos Minerais do Brasil: texto, mapas & SIG**. Brasília: CPRM – Serviço Geológico do Brasil, 2003. p. 577- 601.

HIGUCHI, N. *et al.* Biomassa da parte aérea da vegetação da Floresta Tropical úmida de terra-firme da Amazônia Brasileira. **Acta Amazon.**, v. 28, n. 2, p. 153–153, 1998.

HUETE, A. R. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

IEA - International Energy Agency. Fuels & Technologies: Coal, 2021. Disponível em: <https://www.iea.org/fuels-and-technologies/coal>. Acesso em: 03 set. 2024.

IBRAM – Instituto Brasileiro de Mineração. II INVENTÁRIO DE GASES EFEITO ESTUFA DO SETOR MINERAL. 2014. Disponível em: <https://www.ibram.org.br/>. Acesso em: 03 set. 2024.

JACOB, D. J. *et al.* Satellite observations of atmospheric methane and their value for quantifying methane emissions. **Atmos Chem Phys**, v. 16, n. 22, p. 14371–14396, 2016.

KHOLOD, N. *et al.* Global methane emissions from coal mining to continue growing even with declining coal production. **Journal of Cleaner Production**, v. 256, p. 120489, 2020.

KÖPPEN, W., 1936: Das geographische System der Klimate. KÖPPEN, W., R. GEIGER (Eds.): Handbuch der Klimatologie. Gebrüder Bornträger, Berlin, 1, 1–44, part C.

KOZICKA, K.; GOZDOWSKI, D.; WÓJCIK-GRONT, E. Spatial-Temporal Changes of Methane Content in the Atmosphere for Selected Countries and Regions with High Methane Emission from Rice Cultivation. **Atmosphere-Basel**, v. 12, n. 11, 2021.

KRAUTWURST, S. *et al.* Quantification of CH₄ coal mining emissions in Upper Silesia by passive airborne remote sensing observations with the Methane Airborne MAPper (MAMAP) instrument during the CO₂ and Methane (CoMet) campaign. **Atmos Chem Phys**, v. 21, n. 23, p. 17345–17371, 2021.

LE MAIRE, G. *et al.* MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass. **Remote Sensing of Environment**, v. 115, p. 2613-2625, 2011.

IBGE – Instituto Brasileiro de Geografia e Estatística. MANUAL TÉCNICO DA VEGETAÇÃO BRASILEIRA 2012.

IPCC - Intergovernmental Panel on Climate Change, Guidelines for National Greenhouse Gas Inventories, World Meteorological Organization, 2006. Disponível em: <https://www.ipcc-nggip.iges.or.jp/public/2006gl/vol2.html>. Acesso em: 03 set. 2024.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p.159-174, 1977.

LICKS, L. A.; PIRES, M. Metodologia para o cálculo de emissões de carbono e da eficiência na geração de energia pela combustão do carvão fóssil no Brasil. **REM: R. Esc. Minas**, v. 63, p. 331-337, 2010.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, p. 1297-1328, 2006.

LUDEWIG, A. S5P MPC Product Readme Level 1b V02.01.00. 2023. Disponível em: <https://sentinel.esa.int/documents/247904/3541451/Sentinel-5P-Level-1b-Product-Readme-File>. Acesso em: 07 out. 2024.

MARTINS, L. N.; BAPTISTA, G. M. M. Análise Multitemporal do Sequestro Florestal de Carbono no Projeto de Assentamento Carão, Acre. **Revista Brasileira de Geografia Física**, v. 6, p. 1648-1657, 2013.

MINAMIKAWA, K. *et al.* Appropriate frequency and time of day to measure methane emissions from an irrigated rice paddy in Japan using the manual closed chamber method. **Greenhouse Gas Measurement and Management**, v. 2, n. 2–3, p. 118–128, 2012.

NEEFF, T. *et al.* Carbon budget estimation in Central Amazonia: Successional forest modeling from remote sensing data. **Remote Sens. Environ. (China)**, v. 94, n. 4, p. 508–522, 2005.

PINTO NETO, O.; PINTO, I. R. C. A.; PINTO JÚNIOR, O.; WILLIAMS, E. R. Evidence of a link between Amazon fires and lightning. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 249, 2023. <https://doi.org/10.1016/j.jastp.2023.106095>

PAMPA SUL - Usina Termelétrica PAMPA SUL. Disponível em: <https://www.pampasulenergia.com.br/>. Acesso em: 13 set. 2024.

PARANAÍBA, J. R. *et al.* Spatially Resolved Measurements of CO₂ and CH₄ Concentration and Gas-Exchange Velocity Highly Influence Carbon-Emission Estimates of Reservoirs. **Environmental Science & Technology**, v. 52, p. 607-615, 2018.

PEUKER, K.; FAGUNDES, L. Emissões Fugitivas da Mineração e do Tratamento de Carvão Mineral. *In: Primeiro Inventário Brasileiro de Emissões Antrópicas de Gases de Efeito Estufa, 2006.* Disponível em: <https://repositorio.mcti.gov.br/handle/mctic/5265>. Acesso em: 03 set. 2024.

PIVA, J. T. *et al.* Soil gaseous N₂O and CH₄ emissions and carbon pool due to integrated crop-livestock in a subtropical Ferralsol. **Agriculture, Ecosystems and Environment**, v. 190, p. 87-93. <http://dx.doi.org/10.1016/j.agee.2013.09.008>

QURESHI, A.; PARIVA; BADOLA, R.; HUSSAIN, S. A. A review of protocols used for assessment of carbon stock in forested landscapes. **Environmental Science & Policy**, v. 16, p. 81-89, 2012.

RANGEL PINAGÉ, E. *et al.* Effects of forest degradation classification on the uncertainty of aboveground carbon estimates in the Amazon. **Carbon Balance and Management**, v. 18, n. 1, p. 2, 2023.

ROMERO, F. M. B. *et al.* Allometric Equations for Volume, Biomass, and Carbon in Commercial Stems Harvested in a Managed Forest in the Southwestern Amazon: A Case Study. **Forests**, v. 11, n. 8, p. 874, 2020.

ROUSE, John Wilson; HAAS, Robert H.; SCHELL, John A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. *In: PROCEEDINGS OS THIRD ERTS-1 SYMPOSIUM, 1., 1973, Washington, DC, 1974.* p. 309-327.

SALMAN, A. K. D.; SOARES, J. P. G.; CANESIN, R. C. Métodos de amostragem para avaliação quantitativa de pastagens. Circular Técnica, 84. EMBRAPA, MAPA, 2006.

SANQUETA, C.R.; BALBINOT, R. Metodologias para determinação de biomassa florestal. *In: SANQUETA, C.R.; BALBINOT, R.; ZILLOTTO, M.A.B. Fixação de carbono: atualidades, projetos e pesquisas.* Curitiba. p.77-93. 2004.

SANTOS, D. A.; LOPES, T. R.; DAMACENO, F. M.; DUARTE, S. N. Evaluation of deforestation, climate change and CO₂ emissions in the Amazon biome using the Moran Index. **Journal of South American Earth Sciences**, v. 143, 2024.
<https://doi.org/10.1016/j.jsames.2024.105010>

SANTOS, R. S. *et al.* Avaliação da relação seca/produtividade agrícola em cenário de mudanças climáticas. **Revis. Bras. Meteorol.**, v. 26, p. 313–321, 2011.

SAUNOIS, M. *et al.* 2020. The Global Methane Budget 2000–2017. **Earth System Science Data**, v. 12, n. 13, p. 1561-1623, 2020.

SANTOS, Joaquim. **Análise de Modelos de Regressão para estimar a fitomassa da floresta tropical úmida da terra-firme da Amazônia brasileira**. 1996. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, 1996.

SEEG - Sistema de Estimativa de Emissões de Gases de Efeito Estufa. Base de dados: Emissões por município, 2021. Disponível em:
<http://plataforma.seeg.eco.br/cities/statistics>. Acesso em: 07 jun. 2021.

SILVA, S. C. P.; BAPTISTA, G. M. M. Análises Espectrais da Vegetação com Dados Hyperion e sua Relação com a Concentração e o Fluxo de CO₂ em Diferentes Ambientes na Amazônia Brasileira. **Boletim de Ciências Geodésicas**, v. 21, p. 354-370, 2015.

THENKABAIL, P. S.; SMITH, R. B.; DE-PAUW, E. Hyperspectral vegetation indices for determining agricultural crop characteristics. **Remote Sensing of Environment**, v. 71, p.158-182, 2000.

TIWARY, R. K. Environmental Impact of Coal Mining on Water Regime and its Management. **Water Air Soil Pollut.**, v. 132, p. 185-199, 2001.

TRENCHÉV, P.; DIMITROVA, M.; AVETISYAN, D. Huge CH₄, NO₂ and CO Emissions from Coal Mines in the Kuznetsk Basin (Russia) Detected by Sentinel-5P. **Remote Sensing**, v. 15, 2023.

UNECE - UNITED NATIONS ECONOMIC COMMISSION FOR EUROPE. **Best Practice Guidance for Effective Management of Coal Mine Methane at National Level: Monitoring, Reporting, Verification and Mitigation**. [s.l.] United Nations, 2022.

VEEK, G. P. *et al.* Análise preliminar da relação entre emissão de CO₂ do solo e do ecossistema em um agroecossistema do sul do Brasil. **Ciência e Natura**, v. 40, p. 251-256, 2018. DOI:10.5902/2179460X30897

WANG, J. *et al.* A fibered near-infrared laser heterodyne radiometer for simultaneous remote sensing of atmospheric CO₂ and CH₄. **Optics and Lasers in Engineering**, v. 129, 2020.

WATZLAWICK, Luciano Farinha. **Estimativa de Biomassa e Carbono em Floresta Ombrófila Mista e Plantações Florestais a partir de Dados de Imagens do Satélite IKONOS II**. 2003. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade de Federal do Paraná, Curitiba, 2003.

WU, X. *et al.* Long-Term Trends of Atmospheric CH₄ Concentration across China from 2002 to 2016. **Remote Sensing**, v. 11, n. 5, 2019.

YANG, D. *et al.* Monitoring carbon dioxide from space: Retrieval algorithm and flux inversion based on GOSAT data and using CarbonTracker-China. **Adv Atmos Sci**, v. 34, n. 8, p. 965–976, 2017.

YAO, Z. *et al.* Comparison of manual and automated chambers for field measurements of N₂O, CH₄, CO₂ fluxes from cultivated land. **Atmospheric Environment**, v. 43, p. 1888-1896, 2009. doi:10.1016/j.atmosenv.2008.12.031

ZHANG, J. *et al.* 2022. The Spatial and Temporal Distribution Patterns of XCH₄ in China: New Observations from TROPOMI. **Atmosphere**, v. 13, n. 2, 2022.