



# Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



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

Bruna Lüdtke Paim<sup>1</sup>, Rita de Cássia Marques Alves<sup>2</sup>, Bianca Dutra de Lima<sup>3</sup>

<sup>1</sup> 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](mailto:bruhpaim20@gmail.com) (autor correspondente). <sup>2</sup> 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](mailto:rita.cma@terra.com.br). <sup>3</sup> 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](mailto: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 CO<sub>2</sub>Flux, 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 CO<sub>2</sub>Flux 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 CO<sub>2</sub>Flux, 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, CO<sub>2</sub>Flux 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 Saunois et al. (2020), a mineração do carvão é responsável por aproximadamente um décimo do total das emissões antropogênicas de metano (CH<sub>4</sub>) 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 CO<sub>2</sub> e CH<sub>4</sub> 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 km<sup>2</sup>. 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-Interactive 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 Interactive 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 reflectância fotoquímica da vegetação foi estimada com base no Índice de Reflectância 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,  $\rho G$  é a refletância da banda espectral do verde;  $\rho B$  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 km<sup>2</sup> (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 <sup>2</sup> ) |
|-----------------------|----------|-------------------------|
| 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 espacialmente 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 CO<sub>2</sub>Flux, assumindo valores na faixa de 0,88 e – 0,45, e do XCH<sub>4</sub> 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  $\text{XCH}_4$  apresenta valores mais elevados nas áreas norte e central do município, e mais baixos no extremo sul. Em contrapartida, os valores do índice de  $\text{CO}_2\text{Flux}$  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  $\text{XCH}_4$ , 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  $\text{XCH}_4$  relacionados às regiões de forte atividade agrícola.

Ao analisar as respectivas áreas com dados de  $\text{CO}_2\text{Flux}$  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  $\text{CO}_2\text{Flux}$  (Figura 3). Sendo assim, as distribuições espaciais de  $\text{XCH}_4$  e  $\text{CO}_2\text{Flux}$  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  $\text{CO}_2\text{Flux}$  e  $\text{CH}_4$  na área de estudo entre 2019 e 2022. (a) Classificação realizada pelo método *Random Forest*, (b)  $\text{CO}_2\text{Flux}$  anual, (c)  $\text{CH}_4$  anual.

A distribuição dos dados de  $\text{XCH}_4$  e  $\text{CO}_2\text{Flux}$  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  $\text{XCH}_4$  e  $\text{CO}_2\text{Flux}$  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  $\text{XCH}_4$  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  $\text{CO}_2\text{Flux}$  e  $\text{CH}_4$  na área de estudo entre 2019 e 2022. (a)  $\text{CO}_2\text{Flux}$  verão, (b)  $\text{CH}_4$  verão, (c)  $\text{CO}_2\text{Flux}$  outono, (d)  $\text{CH}_4$  outono, (e)  $\text{CO}_2\text{Flux}$  inverno, (f)  $\text{CH}_4$  inverno, (g)  $\text{CO}_2\text{Flux}$  primavera, (h)  $\text{CH}_4$  primavera.

Para identificar as características de variação temporal das condições de  $\text{CH}_4$  e  $\text{CO}_2\text{Flux}$  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 CO<sub>2</sub>Flux e CH<sub>4</sub> na área de estudo. (a) CH<sub>4</sub> Mineração, (b) CO<sub>2</sub>Flux Mineração, (c) CH<sub>4</sub> Agricultura, (d) CO<sub>2</sub>Flux Agricultura.

A partir dos padrões obtidos, podem ser identificadas algumas características. Enquanto observa-se um crescimento de XCH<sub>4</sub> em diferentes taxas, observa-se um decréscimo de CO<sub>2</sub>Flux 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 CH<sub>4</sub> por ano, e na região intitulada Agricultura, cerca de 9,3 ppb ao ano. A diferença entre os valores máximo e mínimo de XCH<sub>4</sub> 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 XCH<sub>4</sub> 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 CO<sub>2</sub>Flux 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 CO<sub>2</sub>Flux 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 CO<sub>2</sub>Flux 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 XCH<sub>4</sub> 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  $\text{XCH}_4$  tem relação com a distribuição de atividades agrícolas e de produção de energia. Além disso, o  $\text{XCH}_4$  é geralmente mais alto no verão e mais baixo no inverno. Ao analisar as duas regiões com os dados de  $\text{XCH}_4$ , observou-se que em geral o  $\text{XCH}_4$  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  $\text{XCH}_4$  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  $\text{XCH}_4$  e  $\text{CO}_2\text{Flux}$ , 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.; Süsstrunk, 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](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 CO<sub>2</sub> and CH<sub>4</sub>. *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 CH<sub>4</sub> 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 XCH<sub>4</sub> in China: New Observations from TROPOMI. *Atmosphere* [online] 13. Disponível: <https://doi.org/10.3390/atmos13020177>. Acesso: 23 out. 2023.