



UNIVERSIDADE FEDERAL DE GOIÁS (UFG)  
INSTITUTO DE ESTUDOS SOCIOAMBIENTAIS (IESA)  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA (PPGEO)

HELENA GLADIS BOZZO MOREIRA

**Uso do sensoriamento remoto no estudo da distribuição da  
matéria orgânica do solo de uma área úmida isolada de topo  
plano**

GOIÂNIA

2024



UNIVERSIDADE FEDERAL DE GOIÁS  
INSTITUTO DE ESTUDOS SÓCIO-AMBIENTAIS

## TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

### E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

#### 1. Identificação do material bibliográfico

Dissertação     Tese     Outro\*: \_\_\_\_\_

\*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

**Exemplos:** Estudo de caso ou Revisão sistemática ou outros formatos.

#### 2. Nome completo do autor

**Helena Gládis Bozzo Moreira**

#### 3. Título do trabalho

**Uso do sensoriamento remoto no estudo da distribuição da matéria orgânica do solo de uma área úmida isolada de topo plano**

#### 4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento  SIM     NÃO<sup>1</sup>

**[1]** Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

**a)** consulta ao(à) autor(a) e ao(à) orientador(a);

**b)** novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

**Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.**



Documento assinado eletronicamente por **Guilherme Taitson Bueno, Professor do Magistério Superior**, em 05/12/2024, às 15:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Helena Gládis Bozzo Moreira, Discente**, em 05/12/2024, às 15:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **5018133** e o código CRC **ED2C95C3**.

---

HELENA GLADIS BOZZO MOREIRA

**Uso do sensoriamento remoto no estudo da distribuição da  
matéria orgânica do solo de uma área úmida isolada de topo  
plano**

Dissertação apresentada ao Programa de Pós-Graduação em Geografia (PPGeo), do Instituto de Estudos Socioambientais (IESA) da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Mestra em Geografia, na área de concentração em Natureza e Produção do Espaço.

Linha de Pesquisa: Análise Ambiental e Tratamento da Informação Geográfica

Orientador: Prof. Dr. Guilherme Taitson Bueno

Coorientador: Prof. Dr. Jepherson Correia Sales

GOIÂNIA

2024

Ficha de identificação da obra elaborada pelo autor, através do  
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Moreira, Helena Gladis Bozzo

Uso do sensoriamento remoto no estudo da distribuição da matéria orgânica do solo de uma área úmida isolada de topo plano.

[manuscrito] / Helena Gladis Bozzo Moreira. - 2024.

xcv, 95 f.: il.

Orientador: Prof. Dr. Guilherme Taitson Bueno; co-orientador  
Jepherson Correia Sales.

Dissertação (Mestrado) - Universidade Federal de Goiás, Instituto de Estudos Socioambientais (Iesa), Programa de Pós-Graduação em Geografia, Goiânia, 2024.

Bibliografia.

Inclui siglas, abreviaturas, lista de figuras, lista de tabelas.

1. Área Úmida. 2. Matéria Orgânica do Solo. 3. Krigagem. 4. Random Forest. I. Bueno, Guilherme Taitson, orient. II. Título.

CDU 911



UNIVERSIDADE FEDERAL DE GOIÁS

INSTITUTO DE ESTUDOS SÓCIO-AMBIENTAIS

## ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 58/2024 da sessão de Defesa de Dissertação de **Helena Gládis Bozzo Moreira**, que confere o título de Mestra em **Geografia**, na área de concentração em **Natureza e Produção do Espaço**.

Aos **treze dias de novembro de dois mil e vinte e quatro**, a partir das **14:00 horas**, por **videoconferência**, realizou-se a sessão pública de Defesa de Dissertação intitulada **“Uso do sensoriamento remoto no estudo da distribuição da matéria orgânica do solo de uma área úmida isolada de topo plano”**. Os trabalhos foram instalados pelo Orientador, Professor Doutor **Guilherme Taitson Bueno (IESA/UFG)** com a participação dos demais membros da Banca Examinadora: Professor **Doutor Manuel Eduardo Ferreira (IESA/UFG)**, membro titular interno; Professora Doutora **Vania Silvia Rosolen (UEP)**, membro titular externo. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido a candidata **aprovada** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Guilherme Taitson Bueno**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos **treze dias de novembro de dois mil e vinte e quatro**.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Guilherme Taitson Bueno, Professor do Magistério Superior**, em 13/11/2024, às 17:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Manuel Eduardo Ferreira, Professor do Magistério Superior**, em 13/11/2024, às 17:24, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Vania Silvia Rosolen, Usuário Externo**, em 13/11/2024, às 17:31, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4878825** e o código CRC **ABF88A3C**.

Referência: Processo nº 23070.050728/2024-30

SEI nº 4878825

UNIVERSIDADE FEDERAL DE GOIÁS  
INSTITUTO DE ESTUDOS  
SOCIOAMBIENTAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
GEOGRAFIA

HELENA GLADIS BOZZO MOREIRA

**Uso do sensoriamento remoto no estudo da distribuição da  
matéria orgânica do solo de uma área úmida isolada de topo  
plano**

BANCA EXAMINADORA

---

PROF. DR. GUILHERME TAITSON BUENO  
Orientador/Presidente da Banca

---

PROF. DR. MANUEL EDUARDO FERREIRA  
Examinador Interno – PPGeo/UFG

---

PROFA. DRA. VANIA SILVIA ROSOLEN  
Examinadora Externa – UNIVERSIDADE ESTADUAL PAULISTA – UNESP

## RESUMO

A Matéria Orgânica do Solo (MOS) é um indicador da qualidade do solo e o entendimento de sua distribuição é fundamental para o debate acerca da dinâmica do Carbono e da emissão de gases do efeito estufa. Nas últimas décadas, o sensoriamento remoto vem contribuindo para o estudo dos solos e da distribuição da MOS. Este trabalho teve como objetivo avaliar a viabilidade do uso de dados espectrais para estudos de predição e de distribuição espacial do teor da matéria orgânica no horizonte superficial de uma área úmida isolada de topo plano, no município de Cordeirópolis, no estado de São Paulo. Foi produzido um modelo estatístico linear da área úmida para predição da distribuição da MOS, validado por meio da relação entre os índices espectrais analisados e o teor de MOS obtido por amostragem em campo e laboratório. Foi também analisada a evolução do uso da terra no entorno da depressão isolada, entre os anos de 1985 e 2022, a partir de dados disponibilizados na plataforma Mapbiomas. Nos resultados obtidos com o modelo a partir de imagens do satélite Sentinel-2A, o valor mínimo de MOS foi de 22 g/kg e o máximo foi de 47,66 g/kg, o que está de acordo com os dados coletados em campo, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg, com acurácia –  $R^2$  de 0,88, erro quadrado – RMSE de 3,62 e erro médio absoluto – MAE de 2,64. Os resultados com aplicação do modelo para imagens de RPAS (drones) alcançou o valor mínimo de 25,25 g/kg e o valor máximo de 48,92 g/kg de MOS, também próximo dos dados coletados em campo. Na escala dos RPAS, obteve-se  $R^2$  de 0,88, RMSE de 3,62, MAE de 2,85 e erro quadrático médio – MSE de 13,11. Pode-se considerar que o método proposto foi satisfatório na predição dos teores de MOS dos solos da área úmida estudada, demonstrando os ganhos de escala para o uso do método em imagens de satélites e RPAS.

Palavras-chave: Área Úmida, Matéria Orgânica do Solo, Krigagem, Random Forest.

## ABSTRACT

Soil organic matter (SOM) is an indicator of soil quality, and understanding its distribution is fundamental to the debate on carbon dynamics and greenhouse gas emissions. In recent decades, remote sensing has contributed to the study of soils and the distribution of SOM. The objective of this study was to evaluate the feasibility of using spectral data to study the prediction and spatial distribution of organic matter content in the surface horizon of an isolated flat-topped wetland in the municipality of Cordeirópolis, in the state of São Paulo. A linear statistical model of the wetland was constructed to predict the distribution of MOS, which was validated using the relationship between the spectral indices analyzed and the MOS content obtained by field and laboratory sampling. The evolution of land use around the isolated depression between 1985 and 2022 was also analyzed using data available on the Mapbiomas platform. In the results obtained with the model from Sentinel-2A satellite images, the minimum MOS value was 22 g/kg and the maximum was 47.66 g/kg, which is in agreement with the data collected in the field, which ranged from a minimum of 27.55 g/kg to a maximum of 42.07 g/kg, with an accuracy -  $R^2$  of 0.88, a root mean square error - RMSE of 3.62 and a mean absolute error - MAE of 2.64. The results of applying the model to RPAS images (drones) reached a minimum value of 25.25 g/kg and a maximum value of 48.92 g/kg MOS, also close to the data collected in the field. On the RPAS scale,  $R^2$  of 0.88, RMSE of 3.62, MAE of 2.85 and mean square error - MSE of 13.11 were obtained. It can be considered that the proposed method was satisfactory in predicting the MOS content of the soils in the studied wetland, demonstrating the gains in scale for using the method with satellite images and RPAS.

Keywords: Wetland, soil organic matter, kriging, random forest.

## LISTA DE FIGURAS

- Figura 1 - Diagrama representativo, de uma chave de classificação de áreas úmidas.
- Figura 2 - Modelo conceitual dos feedbacks de carbono em uma área úmida.
- Figura 3 - Espectro eletromagnético.
- Figura 4 - Esquema de espacialização do fenômeno a partir da amostragem.
- Figura 5 - Assinatura espectral de diferentes teores de MOS.
- Figura 6 - Mapa de localização do município de Cordeirópolis no estado de São Paulo.
- Figura 7 - Coluna Estratigráfica da região de estudo.
- Figura 8 - Mapa Hipsométrico Regional.
- Figura 9 - Mapa Hipsométrico da Área de Estudo.
- Figura 10 - Fluxograma das etapas metodológicas para execução de modelos preditivos.
- Figura 11 - Malha amostral das coletas realizadas em campo.
- Figura 12 - Malha de extração das variáveis espectrais.
- Figura 13 - Pontos de Coleta e *boxplot* do teor de MOS para o interior e para o entorno da área úmida.
- Figura 14 - Mapa da distribuição de Matéria Orgânica do Solo.
- Figura 15 - *Kriging step*, Semivariograma do Modelo de Covariância.
- Figura 16 - Gráfico de dispersão.
- Figura 17 - Boxplot dos pixels de cada banda de 10 m do satélite Sentinel-2A dentro da área úmida.
- Figura 18 - Matriz de correlação entre as variáveis do Sentinel-2A e a MOS.
- Figura 19 - Gráfico de variâncias acumuladas das dimensões de Análise de Componentes Principais (ACP) entre as variáveis do Sentinel-2A e a MOS.
- Figura 20 - Círculo de Correlação da Análise de Componentes Principais entre as variáveis do Sentinel-2A e a MOS.

Figura 21 - Importância das variáveis pelo Boruta do valor mediana de cada índice do Sentinel-2A.

Figura 22 - Importância das Top Variáveis da Mediana de cada índice dos dados do Sentinel-2A.

Figura 23 - Mapas Top Variáveis, dos índices calculados com o Sentinel-2A.

Figura 24 - Boxplot dos pixels de cada banda do RPAS.

Figura 25 - Matriz de Correlação entre as variáveis do RPAS e a MO.

Figura 26 - Gráfico de variâncias acumuladas das dimensões de Análise de Componentes Principais (PCA).

Figura 27 - Círculo de Correlação da Análise de Componentes Principais

Figura 28 - Importância das variáveis pelo Boruta do valor da média de cada índice calculado com dados do RPAS.

Figura 29 - Importância Top Variáveis da Média de cada índice dos dados de RPAS.

Figura 30 - Mapas Top Variáveis, dos índices calculados com o RPAS.

Figura 31 - Predição de MOS com o sensor MSI do sensor orbital Sentinel 2A

Figura 32 - Predição de MOS com a imagem de RPAS sem as margens laterais da área úmida.

Figura 33 - Comparação de acurácia entre os a krigagem e os modelos preditivos do Sentinel-2A e do RPAS

Figura 34 - Estatísticas do uso da terra do município de Cordeirópolis para os anos de 1985 a 2023, segundo a plataforma MapBiomias.

Figura 35 - Mapa do município de Cordeirópolis e mapas do uso da terra (2000 a 2023).

Figura 36 - Fotos da área de estudo e entorno, registradas em campo.

## LISTA DE TABELAS

Tabela 1 - Características das bandas de interesse geradas pelo instrumento MSI.

Tabela 2 - Fórmulas dos índices espectrais Sentinel 2A utilizados e referências.

Tabela 3 - Características das bandas de interesse geradas pelo instrumento Phantom 4 PRO.

Tabela 4 - Fórmulas do  
índices espectrais RPAS utilizados e referências.

Tabela 5 - Estatística descritiva dos dados de MOS.

Tabela 6 - Mineração dos dados dos *pixels* de cada banda de 10 m do satélite Sentinel-2A na região da área úmida.

Tabela 7 - Mineração dos dados dos índices do satélite Sentinel-2A.

Tabela 8 - Mineração dos dados dos pixels de cada banda RGB do RPAS (Dados Normalizados).

Tabela 9 - Mineração dos dados dos índices do satélite RPAS.

Tabela 10 - Estatística Descritiva dos Modelos de Predição

## **LISTA DE EQUAÇÕES**

Equação 1 - Média

Equação 2 - Variância

Equação 3 - Covariância

Equação 4 - Dispersão para variáveis contínuas e especializadas

Equação 5 - Krigagem ordinária

## LISTA DE ABREVIATURAS E SIGLAS

Agência Espacial Europeia (ESA)

*Google Earth Engine* (GEE)

*Remotely Piloted Aircraft System* (RPAS)

*National Aeronautics and Space Administration* (NASA)

*United State Geological Survey* (USGS)

Instituto Nacional de Pesquisas Espaciais (INPE)

Universidade Estadual Paulista (UNESP)

Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA)

*Intergovernmental Panel on Climate Change* (IPCC)

Instituto Nacional de Meteorologia (INMET)

Instituto Brasileiro de Geografia e Estatística (IBGE)

Companhia de Pesquisa de Recursos Minerais (CPRM)

Área úmida Geograficamente Isolada (AUGI)

Análise de Componentes Principais (ACP)

Raiz do Erro Quadrático Médio (RMSE)

Erro Médio Absoluto (MAE)

Áreas de Preservação Permanente (APPs)

Matéria Orgânica do Solos (MOS)

Ferro (Fe)

Carbono (C)

Carbono Orgânico do Solo (COS)

*MultiSpectral Instrument* (MSI)

Infravermelho Próximo (NIR)

Infravermelho de ondas curtas (SWIR)

*Normalized Difference Vegetation Index (NDVI)*

*Soil-Adjusted Vegetation Index (SAVI)*

*Optimized Soil Adjusted Vegetation (OSAVI)*

*Global Vegetation Moisture Index (GVMI)*

*Moisture Stress Index (MSI)*

*Soil Brightness Index (SBIMSS)*

*Soil Composition Index (SOIL)*

*Ferric (Fe<sup>3+</sup>)*

*Visual Atmospheric Resistance (VARI)*

*Modified Photochemical Reflectance Index (MPRI)*

*Normalized green-red difference index (NGBDI)*

*Red-green-blue vegetation index (RGBVI)*

*Red Green Blue Vegetation Index (RGVBI)*

*Triangular greenness index (TGI)*

*Vegetativen (VEG)*

*Visible Atmospherically Resistant Index (VARI)*

*Daylight Adapted Vegetation Index (DAVI)*

*Normalized Difference Index (NDI)*

*Coloration Index (CI)*

*Color index of vegetation extraction (CIVE)*

*Carotenoid Reflectance Index 1 (CRI\_1)*

*Carotenoid Reflectance Index 2 (CRI\_2)*

*Simple Ratio SR672/550 (RG)*

*Excess green index (EXG)*

*Excess-red index (EXR)*

*Excess green-excess red (EXGR)*

*Green Leaf Index (GLI)*

*Modified Green Red Vegetation Index (MGVRI)*

## Sumário

INTRODUÇÃO .....	12
1. Referencial teórico .....	18
1.1. A matéria orgânica do solo .....	18
1.1.1. As formas da matéria orgânica do solo .....	18
1.1.2. Fatores condicionantes da acumulação de Matéria Orgânica do Solo (MOS) .....	18
1.1.3. O Carbono Orgânico do solo (COS).....	20
1.1.4. O solo como reservatório global de carbono .....	21
1.2. As áreas úmidas .....	22
1.2.1. Áreas úmidas continentais.....	22
1.2.2. Importância das áreas úmidas.....	24
1.2.3. Dinâmica da MOS em solos de áreas úmidas .....	25
1.3. Sensoriamento Remoto e Geoestatística no estudo de matéria orgânica do solo.....	26
1.3.1. Comportamento espectral da matéria orgânica do solo.....	29
1.3.2. Modelagem e Análise multivariada .....	30
2. Materiais e Métodos.....	32
2.1. Área de estudo .....	32
2.2. Procedimentos metodológicos .....	37
2.2.1. Obtenção e tratamento das imagens orbitais e aéreas .....	37
2.2.2. Atividade de Campo.....	40
2.2.3. Atividades de Laboratório .....	41
2.2.4. Espacialização da MOS obtida em campo por Krigagem.....	42
2.2.5. Tratamento estatístico de variáveis de Sensoriamento Remoto .....	44
2.2.5.1. Extração das variáveis espectrais.....	44
2.2.5.2. Estatística descritiva dos dados espectrais e de krigagem.....	44
2.2.5.3. Seleção de variáveis de dados espectrais em relação à MOS .....	45
2.2.5.4. Classificação e acurácia dos modelos gerados pelos índices espectrais orbitais e RPAS.....	46
2.2.6. Comparação dos modelos de predição de MOS .....	46
2.2.7. Estudo do uso da terra no entorno da área úmida .....	47
3. Resultados.....	49
3.1. Distribuição e espacialização do teor de MOS da área úmida.....	49
3.2. Distribuição e espacialização índices espectrais: dados Sentinel-2A .....	52
3.2.1 Índices espectrais derivados de dados Sentinel 2A.....	54
3.2.2 Correlação índices espectrais Sentinel-2A e MOS .....	55
3.2.3 Análise de componentes principais dados espectrais Sentinel-2A e MOS.....	56
3.2.4 Seleção de variáveis Boruta: dados Sentinel-2A .....	58
3.3 Distribuição e espacialização dos índices espectrais e MOS: dados RPAS .....	60
3.3.1 Índices espectrais derivados de dados RPAS .....	62
3.3.2 Correlação índices espectrais RPAS e MOS .....	63
3.3.3 Análise de componentes principais dados espectrais RPAS e MOS.....	64
3.3.4 Seleção de variáveis espectrais pelo Boruta: dados RPAS .....	66
4. Predição de MOS com o satélite Sentinel-2A.....	68
4.1. Predição de MOS por meio de índices espectrais: dados RPAS .....	69
4.2. Comparação dos modelos de predição dados Krigagem x RPAS x Sentinel-2A .....	70
4.3. Análise do uso da terra no entorno da área úmida .....	72
5. Discussão .....	78

5.1.	Cálculo de MOS em pequenas áreas úmidas por krigagem .....	78
5.2.	Predição do teor de MOS em pequenas áreas úmidas por satélites .....	80
5.3	Cálculo de MOS em pequenas áreas úmidas por RPAS .....	81
5.4	Dificuldade de estimativas de MOS e importância da pesquisa .....	82
CONSIDERAÇÕES FINAIS .....		85
Referências Bibliográficas .....		86

## INTRODUÇÃO

Os últimos relatórios do Painel Intergovernamental sobre Mudanças Climáticas apontam para um cenário calamitoso para a humanidade, que envolve desde a elevação da temperatura média da superfície terrestre (IPCC, 2021) até a redução da disponibilidade e da qualidade hídrica no mundo (Makarieva e Gorshkov, 2007). É consenso na comunidade acadêmica que esse cenário se aproxima a cada década e, apesar dos sistemas ambientais estarem em constante transformação (Chorley, 1962) e serem conduzidos por fatores lito-estruturais (Penteado, 1983) e biogeoquímicos naturais (Canfield, 2012), a atividade antrópica inegavelmente acelera e potencializa essas transformações através dos impactos ambientais (Christofolleti, 1979, 1999).

Na região tropical do globo terrestre, um impacto ambiental preocupante resulta do aumento da conversão do uso da terra, em especial a conversão da vegetação nativa em pastagens para a atividade agropecuária (Lal, 2004; Resende e Rosolen, 2013). Esta conversão leva a impactos que vão desde a perda da biodiversidade até a redução da umidade do solo, desencadeando desequilíbrios progressivos nos sistemas ambientais (Makarieva e Gorshkov, 2007).

Do ponto de vista sistêmico, o desequilíbrio devido à conversão da vegetação nativa para outro tipo de uso de solo é caracterizado pela perda (*output*) de carbono do compartimento solo e por uma entrada (*input*) desse carbono em forma de dióxido de carbono para o compartimento atmosfera (Kleidon, 2010). Segundo Lal (2019), o acúmulo progressivo de dióxido de carbono, metano e óxidos nitrosos, provenientes do solo e das atividades antrópicas, no compartimento atmosfera ao longo dos últimos dois séculos, é relevante, porque se soma a diversos *outputs* de dióxido de carbono oriundos de outros compartimentos dos sistemas ambientais (Falkowski, 2012; Lal, 2004), alcançando, a cada década, novos patamares de concentração na atmosfera (IPCC, 2021).

Ainda nas regiões tropicais, o clima úmido e quente favoreceu o predomínio de solos lateríticos. Esses solos apresentam um grau de intemperismo avançado, como consequência pedogenética da latossolização, sob ambiente predominantemente oxidante. Os aspectos físicos dos solos lateríticos do Brasil Central são de boa porosidade, profundidade e drenagem. A mineralogia dominante nesses ambientes apresenta argilas do tipo caulinita e óxidos, como a goethita, a hematita e a gibbsita, além do quartzo (Tardy, 1993).

Entretanto, solos de caráter intrazonal podem coexistir com os solos lateríticos, por exemplo, em áreas sujeitas à saturação hídrica sazonal ou permanente. Nestas áreas, conhecidas como áreas úmidas (*wetlands*), o ambiente redutor desfavorece a formação de óxidos de ferro (Fe) e favorece a acumulação de matéria orgânica no solo. O Fe tem maior mobilidade no estado reduzido, podendo ser lixiviado ou se reoxidar, formando nódulos (Righi; Meunier, 1995). A saída do Fe e a dissociação dos complexos Fe-oxihidróxidos-argilas torna as argilas mais dispersáveis e conseqüentemente mais móveis, podendo ser iluviadas para a base do perfil (Righi; Meunier, 1995). Nesses casos, os horizontes superiores tendem a se tornar mais arenosos e a ter o quartzo como principal componente mineral. Comumente se encontram, da borda para o centro das áreas úmidas, Plintossolos, Gleissolos e Organossolos. Sobre materiais arenosos, em ambientes mais ácidos e com mobilidade de ácidos orgânicos, podem se desenvolver Espodossolos hidromórficos.

As áreas úmidas no interior dos continentes são de vários tipos, como planícies de inundação acompanhando rios, veredas e pantanais. Nesta pesquisa investigamos um tipo específico de área úmida, denominada área úmida isolada, conforme Winter e LaBaugh (2003), ou área úmida geograficamente isolada (AUGI), conforme Tiner (2003) e Furlan et al., (2021). No caso específico desta pesquisa, trata-se de uma área úmida isolada associada a uma depressão, em superfície de topo plano. Por suas dimensões restritas e por se localizar frequentemente em áreas planas, este tipo de ocorrência de área úmida vem sendo fortemente impactado ao longo das últimas décadas pela expansão da atividade agrícola.

O solo, quando não recebe um manejo sustentável, perde, ao longo dos anos, matéria orgânica e umidade (Zech et al., 1997; Lal, 2004). Esse processo reduz o seu potencial produtivo (Lal, 2004; Baldotto e Baldotto, 2018). A matéria orgânica altera os aspectos biológicos, físicos e químicos dos solos, contribuindo para o aumento da disponibilidade de nutrientes através das cargas negativas presentes nos húmus, fornecendo nutrientes para as plantas (Zech et al., 1997; Lal, 2004; Baldotto e Velosso, 2014).

Dentro dos sistemas ambientais, o solo representa um importante e indispensável reservatório de água e nutrientes na superfície terrestre que é composto por componentes orgânicos e inorgânicos, cuja qualidade depende totalmente da forma de manejo (Lal, 2019). As formas de manejo mais sustentáveis dos solos oxídicos, como os manejos agroflorestais ou o plantio direto, favorecem a preservação da matéria orgânica e da umidade do solo (Baldotto e Baldotto, 2018; Lal, 2004). Isso traz vantagens, tanto do

ponto de vista ambiental, quanto do econômico, além de evitar a necessidade de desmatar novas áreas para o cultivo.

A degradação e o avanço da agricultura no entorno e no interior das áreas úmidas aceleram o processo de mineralização do carbono orgânico do solo, agravado pelas consequências da sazonalidade do meio tropical, marcada pela perda de umidade do solo durante alguns meses do ano (Lal, 2019). O estoque de carbono orgânico encontrado em solos hidromórficos, associados a áreas úmidas, aponta para uma maior fragilidade desses ambientes frente às mudanças pluviométricas sazonais, característica nas regiões tropicais.

Os impactos ambientais que as áreas úmidas sofrem, devido aos sistemas agropecuários que bordejam essas áreas hidromórficas deprimidas, são um problema nacional que vem sendo muito discutido no estado de São Paulo, devido à importância que essas áreas têm para a manutenção dos recursos hídricos regionais (Gomes e Magalhães Júnior, 2018; Mitsch et al., 2012), especificamente na depressão periférica paulista, onde muitas dessas áreas úmidas estão cercadas ou foram suprimidas pelo cultivo da cana de açúcar (Junqueira, 2021). O estado de São Paulo já registrou problemas relacionados a períodos prolongados de secas que afetaram diretamente os reservatórios de abastecimento público (Marengo e Alves, 2016; Junqueira, 2021).

Nesse contexto histórico de desmatamento no território do estado de São Paulo, foram produzidos modelos que fornecem prognósticos sobre o clima da região. Segundo Godoy (2021), há uma intensificação de fenômenos extremos de precipitação, o que interfere diretamente no ciclo hidrológico e afeta claramente a área por meio de secas prolongadas e intensas chuvas (Godoy et al., 2021).

No contexto global e regional, esses impactos ambientais causam consequências econômicas e sociais severas, acendendo um alerta às entidades públicas e privadas em relação às consequências do avanço da degradação do meio ambiente (Marengo e Alves, 2016), e tornando patente a necessidade de a comunidade acadêmica avançar no desenvolvimento de métodos que permitam a quantificação de variáveis naturais, utilizando novas tecnologias que colaborem para compreensão dos processos e da dinâmica regional da paisagem. Neste sentido, ressalta-se aqui a contribuição, para esse problema, do avanço da monocultura e das transformações que afetam diretamente as

áreas úmidas da zona rural no Estado de São Paulo (Junqueira, 2021) e no Brasil, em geral.

As pesquisas sobre as propriedades dos solos tradicionalmente se baseiam em levantamentos realizados em campo, em nível de detalhe, seguidos de análises de amostras em laboratório. Esse tipo de levantamento traz consigo, entretanto, uma série de desafios: os altos custos das análises laboratoriais; o descarte dos reagentes poluentes usados nas análises; e a complexidade de locomoção em algumas regiões de difícil acesso. Os altos custos dos trabalhos de campo se devem aos seguintes fatores: dificuldade de locomoção em regiões preservadas, que costumeiramente se encontram em relevos íngremes e de difícil acesso, em áreas rurais contornadas por conflitos espaciais e territoriais, bem como altos custos de investimento em pesquisas que demandam um levantamento sistemático e detalhado de variáveis pedológicas, como dos teores de carbono e matéria orgânica estocados nos solos.

Os trabalhos sobre detecção da matéria orgânica por dados espectrais a décadas são marcados pela tentativa de compreender a resposta desse aspecto do solo entre as faixas 350 - 2500 nm (Galvão e Vitorello, 1998). Nos últimos anos, tem aumentado a relevância pelo desenvolvimento de novas técnicas e instrumentos de sensoriamento remoto para diagnóstico e espacialização do carbono em diferentes profundidades do solo, principalmente por interesses agrícolas (Genú et al., 2010; Moraes et al., 2013; Romagnoli et al., 2015; Pereira, 2015, Silva-Sangoi et al., 2022). Por sua vez, as imagens de sensores orbitais estão se tornando cada vez mais acessíveis, bem como aquelas providas por plataformas aéreas não tripuladas (drones). Além do acesso aberto, as agências espaciais nacionais e internacionais, como NASA, USGS e INPE, estão disponibilizando produtos previamente processados e com melhores resoluções temporal, radiométrica, espectral e espacial. Assim, o sensoriamento remoto vem se mostrando cada vez mais útil para esse tipo de levantamento, apresentando-se como uma técnica que, em conjunto com a geoestatística, possibilita que esses estudos sejam generalizados e reaplicados (Pizarro et al., 2001; Demattê et al., 2004; Genú et al., 2010; Franceschini et al., 2013; Rizzo et al., 2015; Pereira, 2015).

Diante do exposto, a presente pesquisa parte do seguinte questionamento: os dados espectrais, disponíveis em banco de dados gratuitos nas plataformas online, conseguem capturar, direta ou indiretamente, isoladamente ou em conjunto, a distribuição espacial da matéria orgânica do solo presente na camada superficial e imediatamente abaixo da

superfície do solo de uma área úmida, situada em região agrícola de uso intenso? Para responder a esta questão, foi proposto, como objetivo geral desta pesquisa, avaliar a viabilidade do uso de dados espectrais providos pelo programa espacial Copérnicos - Satélite Sentinel-2A, disponibilizadas gratuitamente pela plataforma GEE, para estudos de predição e de distribuição espacial do teor da matéria orgânica na camada superficial e imediatamente abaixo da superfície do solo, numa área úmida em depressão isolada sobre superfície aplanada.

Os objetivos específicos deste trabalho foram: i) determinar a distribuição do teor de matéria orgânica do solo da área úmida estudada, entre 0 e 15 cm de profundidade; ii) espacializar índices espectrais para diversas variáveis ambientais (variáveis contínuas) para a área úmida analisada; iii) produzir um modelo estatístico linear desta área úmida para predição da distribuição da MOS, validado por meio da relação entre os índices espectrais analisados e o teor de MOS obtido por amostragem em campo e análise de laboratório; iv) Analisar a evolução do uso da terra no entorno da depressão isolada entre os anos de 1985 e 2022, visando entender a sua relação com o fenômeno estudado.

Desta maneira, a presente pesquisa se concentrou sobre os componentes do solo de uma área úmida, através do estudo da distribuição da matéria orgânica do solo por meio de sensoriamento remoto. Este estudo é centrado na investigação da capacidade dos sensores multiespectrais em reconhecer o teor de matéria orgânica presente no horizonte superficial do solo de áreas úmidas no estado de São Paulo, buscando, deste modo, interpretar as reais potencialidades e lacunas dessa predição na escala da “unidade geométrica elementar do relevo” (Colangelo, 1996, p.35), em uma depressão isolada no município de Cordeirópolis - SP.

Esta dissertação está dividida em quatro seções principais, além desta introdução: 1) Referencial bibliográfico, que compreende três temas principais: a) a matéria orgânica do solo, os fatores condicionantes de sua acumulação e o solo como reservatório de carbono; b) as áreas úmidas e sua importância ambiental; c) o uso do sensoriamento remoto no estudo da matéria orgânica do solo. 2) Em seguida, é apresentada a seção metodológica do trabalho, compreendendo a caracterização da área de estudo e as técnicas e procedimentos utilizados, a citar: tratamento de imagens orbitais, trabalho de campo, trabalho de laboratório e tratamento estatístico das variáveis analisadas. 3) Na terceira seção são apresentados os resultados e as discussões, trazendo a análise do uso da terra no entorno da área úmida estudada, a distribuição do teor de matéria orgânica do solo da

área úmida; a espacialização dos índices espectrais para as variáveis ambientais; o modelo estatístico linear na região da área úmida, entre índices espectrais associados à matéria orgânica do solo; e a validação do referido modelo. 4) Por fim, o trabalho se encerra com as Considerações Finais.

A presente dissertação está vinculada ao Projeto Fapesp n. 2020/03207-9, denominado “Funções hidrológica e ambiental das áreas úmidas sobre topos planos da Depressão Periférica Paulista”.

## **1. Referencial teórico**

### **1.1. A matéria orgânica do solo**

#### **1.1.1. As formas da matéria orgânica do solo**

Segundo Duchaufour (1960), a matéria orgânica do solo tem como fonte principal os detritos vegetais de diferentes naturezas, como folhas e galhos mortos, que são decompostos mais ou menos rapidamente pela atividade biológica desde sua chegada ao solo. A matéria orgânica fresca (serrapilheira) é constituída pelo conjunto dos materiais orgânicos de origem biológica, em diferentes estágios de decomposição, compreendendo vegetais, animais ou micróbios, aéreos ou subterrâneos, assim como os excrementos de animais depositados diretamente no ambiente (Gobat et al., 2010).

A matéria orgânica fresca é pouco a pouco transformada, dando origem, por um lado, a elementos minerais solúveis ou gasosos como  $\text{NH}_3$ ,  $\text{NO}_3\text{H}$  e  $\text{CO}_2$  (por mineralização ou biodegradação), e, por outro lado, a complexos coloidais (húmus), que são relativamente estáveis e resistentes à ação microbiana (humificação). Estes compostos húmicos também irão se mineralizar, mas em ritmo mais lento (Duchaufour, 1960).

A matéria orgânica resultante da humificação pode ser classificada segundo sua massa molecular. Os principais são os ácidos fúlvicos, os ácidos húmicos e a humina. Os ácidos fúlvicos são de cor amarelada. Possuem longas cadeias laterais de natureza alifática ou peptídica e um núcleo aromático de pequeno tamanho. São muito reativos por meio de seus grupos  $-\text{COOH}$  dissociados, que se ligam com cátions bivalentes devido à sua eletronegatividade (Gobat et al., 2010). Os ácidos húmicos, por sua vez, possuem cadeias laterais mais curtas, ligadas a um núcleo aromático mais importante. Os ácidos húmicos são mais estáveis do que os ácidos fúlvicos. A humina, por sua vez, é extremamente estável e se fica solidamente sobre as argilas ou sobre géis coloidais, garantindo sua perenidade estrutural (Gobat et al., 2010).

#### **1.1.2. Fatores condicionantes da acumulação de Matéria Orgânica do Solo (MOS)**

Segundo Carvalho et al., (2023), há duas vias principais que promovem a estabilização da matéria orgânica do solo: (i) a via biológica, que envolve mecanismos relacionados com as plantas, a fauna e os microorganismos, e (ii) a via abiótica, que está relacionada com a localização espacial da MOS e com as interações organo-minerais

(Dignac et al., 2017). Os autores citam, ainda, os fatores antrópicos, como o uso da terra e as práticas de manejo, que podem alterar a dinâmica do Carbono (C).

No presente trabalho, será dada maior ênfase aos fatores abióticos, determinados pelo meio físico, uma vez que a área de estudo se encontra em um ambiente especial (área úmida em depressão topográfica) em meio tropical. Considerando fatores abióticos, a mineralogia do solo pode ser um fator importante para a estabilização e acumulação da MOS (Carvalho et al., 2023). Segundo esses autores, citando Kaiser e Guggenberger (2003); Tombácz et al., (2004) e Rasmussen et al., (2018), o potencial de solos altamente intemperizado para reter MOS poderia ser parcialmente explicado pela dominância de óxidos de Fe e Al na fração argila. Devido à sua alta reatividade, grande área superficial e muitos sítios de troca, os óxidos de Fe e Al desempenham um papel importante na formação de complexos organo-minerais e na estabilização da matéria orgânica. Solos com teores elevados de argila também pode retardar a decomposição da matéria orgânica, pois, além de estabelecer pontes com compostos orgânicos, possuem capacidade de retenção de água e, conseqüentemente, restringem a disponibilidade de oxigênio do meio (Chapin III et al., 2002).

Em uma escala macroscópica, é reconhecido na literatura (Sollins et al., 2006; Carvalho et al., 2023) que a agregação do solo pode influenciar o acesso à matéria orgânica pela fauna e pelos microorganismos decompositores, por oclusão, reduzindo, ainda a difusão de reagentes e dos produtos das reações. A porosidade do solo, por sua vez, pode também limitar o acesso à matéria orgânica às bactérias e fungos, sobretudo se a porosidade for menor do que 2  $\mu\text{m}$  (Lützow et al., 2006). Portanto, solos com agregados estáveis tendem a desfavorecer a mineralização da matéria orgânica, enquanto uma grande quantidade de macroporos tende a favorecer esse processo.

A disponibilidade de nutrientes no solo e a qualidade dos compostos orgânicos também é um fator importante para a taxa de decomposição da matéria orgânica. Segundo Cunha-Santino; Bianchini Júnior (2023), as bactérias heterotróficas se desenvolvem mais rapidamente em ambientes com maior quantidade de nutrientes e onde predominam os complexos orgânicos aminoácidos, vitaminas, e bases nitrogenadas (purinas e pirimidinas). O pH é outro fator do solo que interfere na mineralização da matéria orgânica. Em geral, a decomposição ocorre mais rapidamente em ambientes de pH neutro, do que em ambientes ácidos e isso se deve a vários fatores que interagem entre si. Nos ambientes ácidos tendem a predominar os fungos, enquanto o aumento na

representatividade das bactérias parece acompanhar maiores taxas de decomposição, em pH neutro (Chapin III et al., 2002).

O fator climático tem influência direta na dinâmica da matéria orgânica, uma vez que temperaturas mais elevadas e maior umidade favorecem as reações químicas, a atividade biológica e a liberação da matéria orgânica dissolvida (Kalbitz; Knappe, 1997, citados por Gmach et al., 2020). A temperatura é considerada globalmente o principal controle ambiental da ciclagem da matéria orgânica, seguida pela disponibilidade de oxigênio e de nutrientes. Entretanto, em regiões onde as variações de temperatura não são muito acentuadas, como no meio tropical, a disponibilidade de oxigênio se torna mais importante (Cunha-Santino; Bianchini Júnior, 2023). Isso se torna ainda mais evidente quando se trata de áreas úmidas.

A disponibilidade de oxigênio no solo tem relação direta com a profundidade do nível freático que, por sua vez, é afetada por fatores topográficos, geológicos e pedológicos. Em áreas topograficamente deprimidas, é comum que a profundidade do nível freático se reduza. Igualmente, isso pode ocorrer caso haja no perfil de solo um forte gradiente de permeabilidade, que pode ser resultado da presença de uma camada mais argilosa do substrato geológico ou de horizontes pedogenéticos mais argilosos, na base do perfil.

A oxidação da matéria orgânica é interrompida pela saturação hídrica do solo por submersão, e os microorganismos aeróbios consomem o oxigênio do solo e se tornam inativos ou morrem. A falta de oxigênio tem sérias consequências para a decomposição da matéria orgânica, pois os decompositores aeróbios obrigatórios, como as bactérias e os fungos, ficam restritos aos setores mais aerados do solo (Chapin III et al., 2002).

### **1.1.3. O Carbono Orgânico do solo (COS)**

Segundo Pribyl (2010), desde o trabalho de Sprengel (1826), convencionalmente é aceito que 58% da matéria orgânica do solo é constituída por C, do que resultou o conhecido fator de conversão de 1,724 entre MOS e COS. Entretanto, os resultados de técnicas mais modernas de obtenção dos teores, tanto de COS, quanto de MOS, vêm demonstrando que, em geral, este valor é superestimado e que um fator de 2, baseado no pressuposto de que a matéria orgânica é composta por 50% de carbono seria, na maioria dos casos, mais preciso do que o fator convencional de 1,724 (Pribyl, 2010).

Ainda segundo este autor, o fator de conversão também pode variar muito, sendo influenciado por variáveis como o tipo de cobertura vegetal, composição da matéria

orgânica, profundidade no perfil, quantidade de matéria orgânica e de argila no solo e grau de decomposição da matéria orgânica. Solos em áreas pantanosas, por exemplo, podem ter teores mais elevados de C, atingindo teores de 70 a 78% (Robinson, 1927 citado por Pribyl, 2010). Entretanto, por motivos de conveniência e tradição, o teor de 58% continua sendo o mais aceito (Pribyl, 2010).

#### **1.1.4. O solo como reservatório global de carbono**

Nos sistemas ambientais, a matéria (carbono, oxigênio, nitrogênio, enxofre, ferro etc.) é transportada entre os compartimentos (atmosfera, solos, aquíferos etc.) ao longo de ciclos biogeoquímicos (Canfield, 2012; Christofolleti, 1979, 1999). O solo é um importante compartimento de armazenamento de carbono da superfície da terra, exercendo a função ambiental de sumidouro; esse reservatório possui aproximadamente a capacidade de captura anual entre 0,9 e 0,3 PgC (Lal, 2004, p.18). Segundo Lal (2004), esse potencial faz do solo um compartimento significativo para a mitigação das entradas excessivas de carbono na atmosfera.

As moléculas orgânicas presentes nos tecidos dos organismos e microorganismos em decomposição, ou na estrutura da vegetação, como folhas e galhos, em conjunto com a água, são conduzidas para dentro dos poros, penetrando na camada superficial do solo. Observando-se através da lente sistêmica ao longo do tempo, esses componentes biológicos são guiados pela gravidade, através da infiltração, processo que ocorre como um dreno (*input*) de matéria orgânica para o compartimento solo, transformando as características pedológicas em profundidade.

As características pedológicas que se alteram pela presença da Matéria Orgânica do Solo (MOS) são químicas, físicas e biológicas. Acrescenta-se a isso o fato de que os diferentes tipos de vegetação e tipos de organismos encontrados alteram também a composição e propriedades contidas na MOS, como estrutura e estabilidade (Zech et al., 1997). As diferentes propriedades do Carbono Orgânico do Solo (COS) influenciam na qualidade da MOS e, conseqüentemente, na estabilidade física dos agregados, na fertilidade química e na velocidade de mineralização desse material biológico (Resende e Rosolen, 2013; Lal, 2019).

Segundo Baldotto e Baldotto (2018), quando há ocorrência de alta atividade biológica do solo, outras propriedades apresentam correlação positiva, que são o pH, o ponto de carga zero e o potencial redox (redoximorfismo), deste modo, alterando a velocidade de

solubilização dos cátions e íons presentes nos sítios de troca (Mitsch e Gosslink, 2015). Em ambientes florestais, que têm sua biodiversidade preservada, os solos apresentam agregados com uma estrutura mais estável e oxigênio disponível nos poros, que possibilitam que microorganismos utilizam as moléculas orgânicas como fonte de energia, mineralizando essa MOS de forma equilibrada, compondo também os aspectos biológicos e intrínsecos ao solo (Lal, 2004).

## **1.2. As áreas úmidas**

### **1.2.1. Áreas úmidas continentais**


Mudanças ambientais geram alterações no equilíbrio dinâmico do sistema ambiental, essa alteração no *feedback* tem a tendência de mudar características da morfologia da paisagem (Chorley, 1962). No contexto da paisagem, as áreas úmidas representam subunidades (Bertrand, 2004), normalmente enquadradas no nível de geofácies ou de geótopo. Os aspectos vegetacionais e hidrológicos estão relacionados ao relevo onde estão inseridos e aos parâmetros que o conservam (Brison, 1993; Mitsch e Gosslink, 2015). Gomes e Magalhães Júnior (2018) descrevem as principais chaves de classificações internacionais de áreas úmidas. Entre as classificações citadas, destacam-se os diagramas da África do Sul criados por Ollis (2013), que, em consonância com a convenção internacional Ramsar, criou um sistema de classificação de áreas úmidas; esse sistema foi criado em forma de um glossário, simplificando a identificação.

De forma geral, a classificação é dividida em seis níveis, que vão se complementando, detalhando as características e especificidades (Ollis, 2013). O primeiro nível é o mais abrangente, iniciando a classificação na escala dos grandes ecossistemas (Ollis, 2013). O segundo nível é ainda abrangente, englobando aspectos da paisagem, inserindo noções geomorfológicas de funções e processos (Ollis, 2013). O terceiro nível é o regional, onde é necessário um contexto biogeográfico (Ollis, 2013). O nível 4 afunila a classificação, entrando nas unidades hidrogeomórficas e classificando essas áreas de acordo com aspectos físicos e hidrológicos (Ollis, 2013). O nível 5 é o mais complexo, porque precisa de mais dados, como a frequência e a duração da inundação desses sistemas. O nível 6 distingue esses sistemas através de características estruturais, químicas e biológicas por meio de uma descrição mais aprofundada (Ollis, 2013).

Todas as classes trazidas por este autor são imprescindíveis para a compreensão e conservação dessas regiões tão sensíveis. Neste trabalho, o contexto regional é ilustrativo

para a contextualização da área úmida isolada no topo plano, e como a região fica em ambiente subtropical, esse nível da classificação é enriquecedor para o tipo de área úmida estudada neste trabalho. Então, ainda segundo Ollis (2013), as depressões hidromórficas que estão vinculadas às regiões planas ou de baixa declividade são suscetíveis à precipitação e aos fluxos subterrâneos. Deste modo, a presença da umidade é consequência das flutuações hídricas e estão interligadas aos fluxos verticais e laterais em subsuperfície (Figura 1), sendo conceitualmente definida como “(...) uma zona úmida ou ecossistema aquático com contornos de elevação fechados, que aumentam de profundidade a partir de perímetro para uma área central e dentro da qual água se acumula normalmente.”<sup>1</sup> (Ollis et al., 2013; p.29).

Figura 1 - Diagrama representativo de uma chave de classificação de áreas úmidas.



Fonte: Adaptado OLLIS, Dean et al., (2013, pág. 19).

Optou-se neste trabalho por utilizar a expressão “depressão isolada” conforme proposto por Winter; LaBaugh (2003) e Ollis (2013, p35), pois a depressão estudada não apresenta ligação superficial com a rede hidrográfica, inferindo-se a existência de fluxos

<sup>1</sup> “(...) a wetland or aquatic ecosystem with closed elevation contours, which increases in depth from the perimeter to a central area of greatest depth and within which water typically accumulates” (Ollis et al., 2013; p.29).

subterrâneos. Para confirmar a existência de fluxos subterrâneos; entretanto, seriam necessários estudos hidrológicos, como aqueles realizados por Casagrande et al., (2021).

### **1.2.2. Importância das áreas úmidas**

Cada área úmida pode ser considerada, individualmente, um ecossistema (Bhowmik, 2020). Isso pode ser entendido tanto por constituírem um ambiente que se diferencia do seu entorno, quanto por sua singularidade em comparação com outras áreas úmidas, mesmo que situadas na mesma região. Trata-se de sistemas que se diferenciam por sua biodiversidade, microclima, regime hidrológico, serviços ecossistêmicos, tipos de solos e sedimentos, atividade antrópica, índices de contaminação (Bhowmik, 2020).

Leibowitz (2003) aponta duas principais funções para as áreas úmidas isoladas: hidrológica e como habitat. Do ponto de vista hidrológico, ressalta que o armazenamento da água tanto alimenta fluxos subterrâneos, retardando a liberação da água, quanto permite a evapotranspiração, reduzindo os picos de cheia nos cursos d'água em comparação com bacias em que predomina o escoamento superficial.


Quanto à função como habitat, a diversidade de ambientes no interior das áreas úmidas deprimidas resulta em riqueza de espécies tanto dentro da área úmida quanto no seu entorno e no espaço entre as áreas úmidas (Leibowitz, 2003). Segundo esse autor, uma das formas pelas quais a diversidade vegetal se expressa é por meio da zonalidade: anéis concêntricos de vegetação possuindo diferentes espécies, que ocorrem ao longo do gradiente de umidade entre a periferia e o centro da área úmida. Além disso, as áreas úmidas em depressão também experimentam variação hidrológica sazonal e interanual, modificando a quantidade e o gradiente de umidade.

Leibowitz (2003) afirma que áreas úmidas em depressão podem incluir espécies endêmicas, como resultado de restrições na dispersão entre áreas úmidas espacialmente separadas, o que resulta em restrições no fluxo genético.

As áreas úmidas isoladas se destacam também como áreas de sequestro de carbono. O sequestro do C nos solos das áreas úmidas é diferente das outras regiões na superfície da terra e um dos principais fatores que diferencia as áreas úmidas, por exemplo, é o ambiente anaeróbico presente no solo, gerado pelo contato entre o aquífero livre em subsuperfície e a presença predominante de água nos poros do solo em superfície (Mitsch e Gosslink, 2015).

Mitsch et al., (2012) desenvolveram uma modelagem envolvendo o sequestro e perda de carbono e metano dos solos de algumas áreas úmidas espalhadas pelo mundo. Um dos seus resultados mostra que, no mundo, essas áreas úmidas teriam o potencial de sequestro próximo a 830 Tg/ano (Mitsch et al., 2012, p.595). Além disso, os pesquisadores construíram um modelo conceitual de entradas e saídas de carbono no sistema úmido (Figura 2).

Figura 2 – Modelo conceitual dos *feedbacks* de carbono em uma área úmida.



Fonte: MITSCH et al., 2012, pág.589.

Entretanto, mudanças hidrológicas induzidas por distúrbios climáticos ou antrópicos podem modificar as taxas e a composição dos gases emitidos pelos sistemas de áreas úmidas. Por exemplo, a drenagem do solo abaixa o nível freático e eleva o conteúdo de oxigênio do solo, aumentando as emissões de  $\text{CO}_2$  (Chapin III et al., 2002).

### 1.2.3. Dinâmica da MOS em solos de áreas úmidas

Os resíduos orgânicos presentes predominantemente nos horizontes dos solos são celulose, lignina, hemicelulose, esterco, microbiota, mesobiota e macrobiota. A dinâmica da MOS envolve transformações dos resíduos orgânicos em materiais orgânicos, muitas vezes triturado e revolvido pela própria biota. Assa MOS humificada é composta por humina, ácido húmico e ácido fúlvico (Duchaufour, 1982).

Existem áreas úmidas muito humificadas e áreas úmidas pouco humificadas e as flutuações hidrológicas geram diferentes estágios de decomposição dos compostos orgânicos, como produto dos ciclos das oxidações e oxirredução causados em ambientes com presença de ferro e raízes, alterando a morfologia do solo (Mitsch e Gosselink, 2015).

A distribuição da MOS em áreas úmidas do tipo depressão isolada de topo depende da dinâmica físico-hídrica dos solos encontrados ao longo da topografia. Logo, a dinâmica do COS encontrado nessas regiões se deve aos diferentes graus de saturação e de humificação. Segundo estudos de caso realizados por Tomazela (2020) e Casagrande et al., (2021) em uma das áreas úmidas isoladas da depressão periférica paulista, os solos encontrados na borda dessa depressão apresentam uma percolação vertical alta e que vai reduzindo a velocidade centripetamente na depressão.

A velocidade da atividade biológica está diretamente relacionada com o comportamento hídrico determinando, portanto, se o solo é mais mineral ou mais orgânico. Segundo Mitsch e Gosselink (2015, p. 161), para que um solo hidromórfico seja considerado orgânico é preciso ter mais de 35% de matéria orgânica do seu peso total seco. A labilidade da matéria orgânica colabora com uma importante propriedade a ser considerada quando falamos de variabilidade e caracterização de áreas úmidas: a humificação ou mineralização, que definem e diferenciam os processos evolutivos de cada paisagem onde esses ambientes estão inseridos.

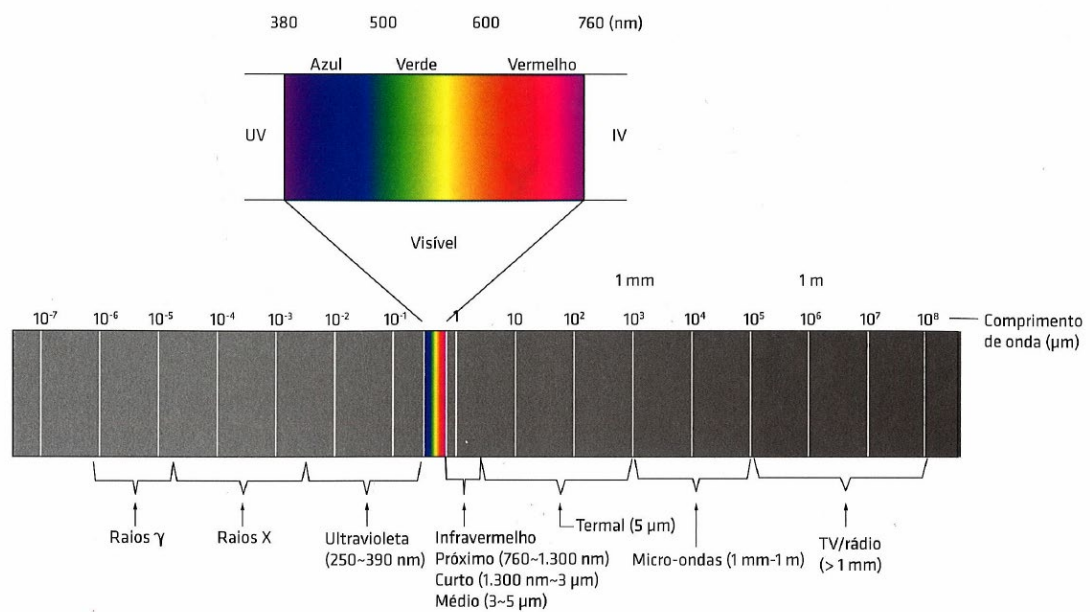
O ambiente saturado altera a química do solo tornando o ambiente redutor, ou seja, sem oxigênio suficiente para que as plantas lenhosas possam se desenvolver. Por esse motivo, o comportamento hidrológico é um dos fatores considerados nas chaves de classificação das áreas úmidas e a vegetação como consequência é um importante marcador em relação à dinâmica desse comportamento (Ollis et al., 2013).

### **1.3. Sensoriamento Remoto e Geoestatística no estudo de matéria orgânica do solo**

O sensoriamento remoto é uma técnica que diferencia os alvos presentes na superfície terrestre através da energia eletromagnética. O fenômeno da resposta espectral envolvido ocorre da seguinte maneira: a energia que o sol emite incide no alvo e parte dessa energia é refletida (Meneses, 2019). O sensor capta essa energia refletida e quantifica a absorvida. A partir dessa quantificação, é gerada uma assinatura espectral (Meneses, 2019).

A visão humana capta apenas uma faixa das ondas eletromagnéticas, denominada faixa do visível, situada entre os comprimentos de onda de 380 e 760 nm. Dentro do campo do sensoriamento remoto, existem diferentes tipos de sensores que captam diferentes canais das ondas eletromagnéticas (Figura 3).

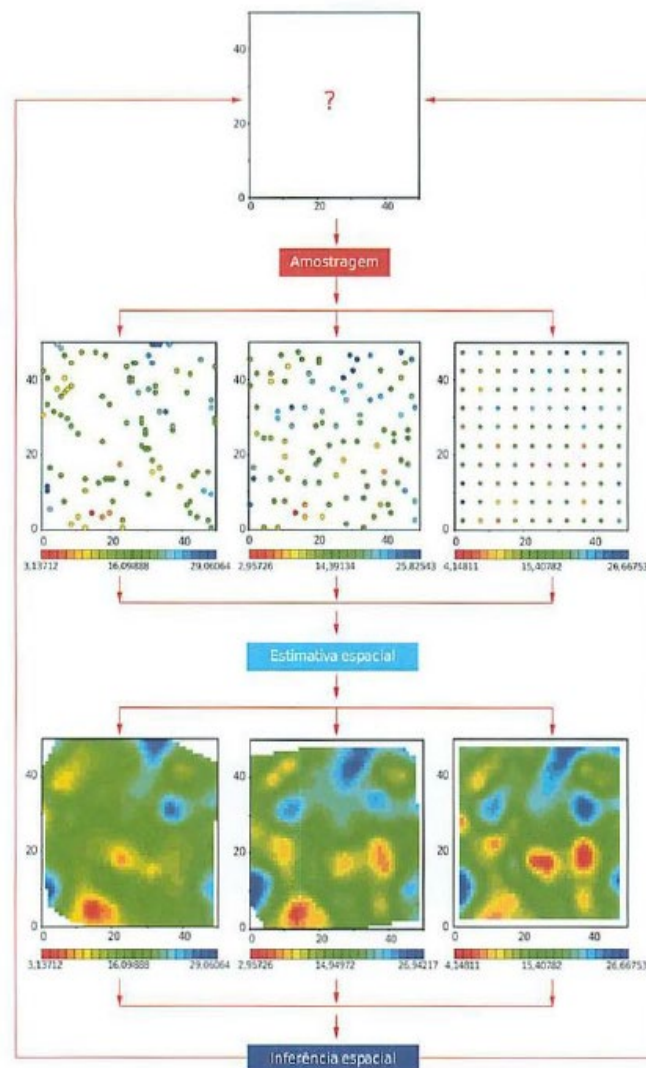
Figura 3 - Espectro eletromagnético.



Fonte: MENESES, 2019. p.13.

Cada alvo possui diferentes valores de reflectância. Esses valores dependem da composição do alvo estudado, sendo possível definir objetos e classificar propriedades dos alvos a partir desses valores de reflectância. A geoestatística possibilita a espacialização de dados amostrais de reflectância, de forma que expresse um “fenômeno espacial” (Yamamoto e Landim, 2015) como podemos observar na Figura 4.

Figura 4 - Esquema de espacialização do fenômeno a partir da amostragem.



Fonte: YAMAMOTO e LANDIM, 2013, pág.13.

A caracterização das propriedades pedológicas através do sensoriamento remoto depende da sensibilidade do sensor utilizado para captar a propriedade do solo de interesse, enquanto a maneira em que será realizado o levantamento amostral determinará o detalhamento da variabilidade da variável investigada na camada superficial do solo. No campo da pedologia, o sensoriamento remoto e a geoestatística surgem como ferramentas que buscam solucionar várias questões que abarcam desde a predição de propriedades pedológicas até a espacialização de classes pedológicas (Pizarro, 2001; Genú et al., 2010; Franceshini et al., 2013; Rizzo, 2015; Meneses, 2019; Demattê et al., 2004).

O carbono encontrado na superfície do solo está no centro de muitos estudos acadêmicos que envolvem desde a estatística básica, como correlação de Pearson

(Baldotto e Velosso, 2014), até estatísticas mais complexas, como a análise de componentes principais (Genú et al., 2010; Franceshini et al., 2013), ambas objetivando a caracterização pedológica com o uso de sensoriamento remoto para uma espacialização com precisão e com menores custos.

Alguns autores que trabalharam o comportamento pedológico com espectroscopia, buscando entender o comportamento do solo na faixa do infravermelho, foram Franceschini et al., (2013) e Rizzo (2015). Ambos os estudos identificaram sensibilidade dos alvos nesse canal, detectando nas feições de absorbância aspectos mineralógicos e estabelecendo relações quanto ao grau de intemperismo, possibilitando a delimitação das classes pedológicas.

O infravermelho é uma região do espectro eletromagnético que vem se mostrando muito útil para outros tipos de estudos ambientais. Por esse motivo muitos índices que inicialmente foram pensados para aplicação na vegetação, hoje são utilizados para aplicações em estudos geológicos e pedológicos.


### **1.3.1. Comportamento espectral da matéria orgânica do solo**

O estudo de carbono no solo é um campo da pedologia que tem muita importância e a modelagem das quantidades de carbono no solo tem ganhado cada vez mais espaço nas últimas décadas. Existem diferentes tipos de modelagem que possibilitam análises espaço-temporais do comportamento das propriedades do solo. Alguns autores que utilizaram análise multivariada para prever quantidades de carbono através dos valores dos espectrorradiômetros são Romagnoli et al., (2015) e Genú et al., (2010). Muitos trabalhos usam a biblioteca espectral da NASA como referência do padrão da assinatura espectral dos alvos (Pizarro et al., 2001; Meneses, 2019).

Os hiperespectrais e os sensores ativos, apesar dos seus altos custos, avançam ainda na abrangência da análise. O sensor ativo denominado espectrorradiômetro permite que se levante a assinatura espectral de forma que não apresente ruídos. Os sensores hiperespectrais, que operam em bandas mais curtas, são também importantes, porém esses sensores captam grandes quantidades de canais. Os sensores hiperespectrais, por exemplo, captam aspectos mineralógicos do solo (Pizarro et al., 2001; Genú et al., 2010; Meneses, 2019) e alguns autores que utilizaram o método cluster para agrupar dados espectrais para quantificar propriedades pedológicas foram Galvão e Vitorello, (1998) Demattê et al., (2004), Genú et al., (2010) e Pereira (2015).

Galvão e Vitorello em 1998 trabalharam com 36 amostras de solo, especificamente com os teores de  $S_iO_2$ ,  $F_eO_3$ ,  $T_iO_2$  e  $Al_2O_3$  e de MOS para compreender o papel da MOS na faixa espectral de 400 a 2500, eles concluíram que a MO reduz o potencial de refletância. Hong et al., (2019) produziram um levantamento de 535 amostras para refinar e ajustar a acurácia da predição de MOS. Na Figura 5 é possível notar a assinatura espectral da MOS com diferentes teores de MOS.

Figura 5 – Assinatura espectral de diferentes teores de MOS.



Fonte: Adaptado HONG et al, 2019. p.108.

A captação das características morfológicas dos elementos que compõem a paisagem produz um valor médio para cada *pixel*, então esse valor é condicionado ao ambiente em que cada objeto estiver inserido, estando sujeito a variações por interferência. Ao longo do tempo, os diversos trabalhos produzidos comprovaram que a presença de MO interfere na resposta espectral, resultando no *pixel* um aspecto mais opaco (Galvão et al., 1998, Franceshini et al., 2013; Pereira, 2015; Pizarro, 2001; Meneses et al., 2019).

As áreas úmidas entram na categoria de APPs, os solos predominantes dessas regiões na maioria das vezes não são expostos, deste modo, o *pixel* sofre interferência da vegetação e do solo, ao mesmo tempo. O ambiente saturado do horizonte pedológico dessas áreas úmidas, reduz a velocidade de atividade microbiana, causada pela redução de oxigênio disponível, desta forma também reduzindo a velocidade da decomposição desses compostos orgânicos. Como nesta pesquisa estudamos MOS em áreas de solos úmidos, suas propriedades dependentes do aspecto hidrológico podem ser inferidas pela resposta fornecida pela cobertura vegetal, mesmo que estes solos não estejam expostos.

### 1.3.2. Modelagem e Análise multivariada

A MOS é um dos principais aspectos dos solos que afetam a reflectância da superfície (Genú et al., 2010), trazendo ainda mais relevância para os estudos de modelagens que são realizadas com dados de sensoriamento remoto. Os estudos sobre modelagens pedológicas foram se aprimorando ao longo das últimas décadas. Esses modelos foram aplicados em diversas escalas de estudos, englobando, no campo da geoestatística, comparações entre diferentes tipos de regressões (Romagnoli, 2015), agrupamentos (Demattê, 2004) e *machine learning* (Pereira, 2015) que envolve comandos com um conjunto de equações, possibilitando uma maior abrangência espaço-temporal. A aplicação de agrupamentos como *clusters* e *kmeans* em dados multisensores padronizados andam em consonância com a aplicação de diferentes tipos de regressão.

Vários trabalhos comparam as predições realizadas por modelagem com outros tipos de variáveis, como dados espectrais, com a distribuição de MOS realizada pela krigagem predita por coletas (Chen et al., 2019; Kennedy Were et al., 2015; Bouslihim et al., 2024; Zhang et al., 2021). Outro método de detecção muito utilizado de propriedades do solo envolve, quantificar a interferência de MOS através da reflectância preditas por análises multivariadas e equações logarítmicas (Galvão et al., 1998, Morais et al., 2013; Romagnoli, 2015; Pereira, 2015; Demattê, 2004); são desenvolvidos muitas vezes em conjunto com algumas técnicas de classificação através de redes neurais e matriz de confusão, todas possibilitam o cálculo da precisão e da acurácia.

Os trabalhos que envolvem essa temática propõem, na maioria das vezes, buscar outras variáveis que consigam prever aproximadamente quanto de MOS tem em uma região sem necessariamente precisar coletar amostras. A possibilidade de detecção dessa variabilidade de carbono através dos dados multisensores, correlacionando com a variabilidade dos valores dos *pixels*, aponta para uma capacidade de detecção dos sensores multiespectrais da variabilidade do grau de humificação na região da área úmida por estar relacionada com o teor de umidade na superfície do solo na escala dessas unidades ambientais.

## 2. Materiais e Métodos

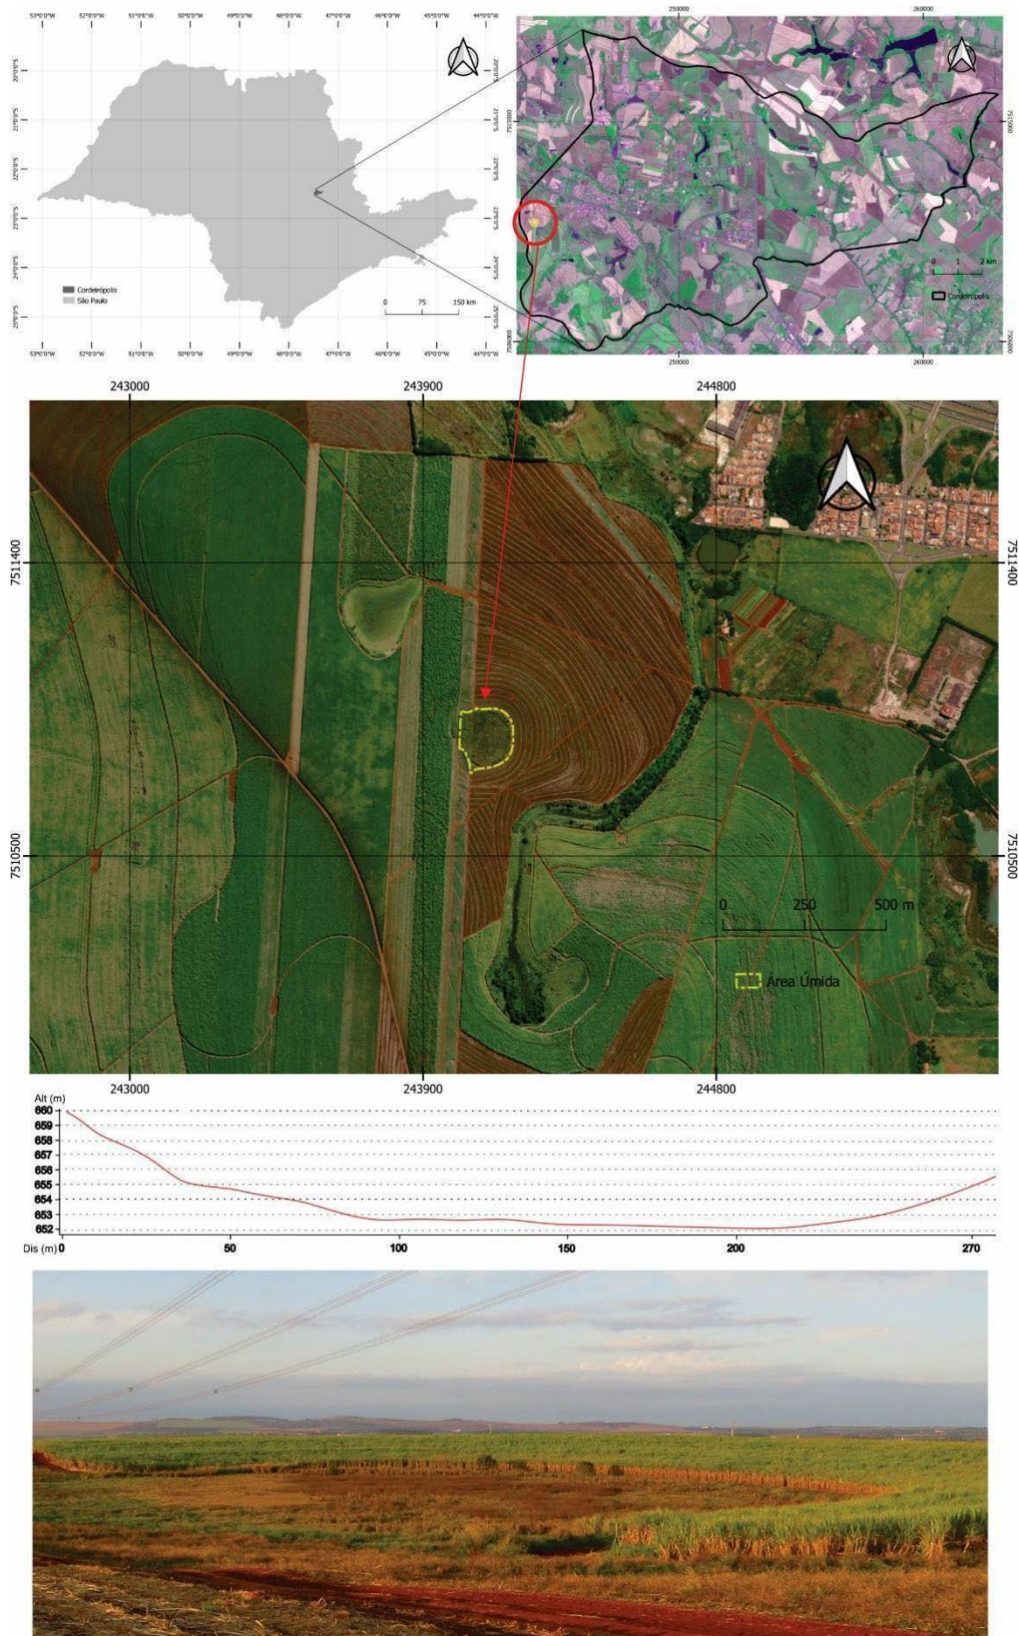
### 2.1. Área de estudo

O sítio de pesquisa é uma área úmida caracterizada como uma depressão isolada com uma área de aproximadamente 25.823 m<sup>2</sup> e com aproximadamente 162 m de diâmetro. Essa depressão está localizada na região central do estado de São Paulo, especificamente no município de Cordeirópolis que possui área total de 137,579 km<sup>2</sup> e se encontra na microrregião de Limeira (IBGE, 2023). A depressão isolada está contornada por cana-de-açúcar. Suas bordas estão delimitadas por uma estrada de solo exposto, assim como as depressões adjacentes, como podemos observar na Figura 6.

A região se encontra próxima ao limite da região tropical, tendo períodos chuvosos de longa duração entre os meses de outubro e março, com média pluviométrica diária de 6 mm/dia e com temperatura média mínima de 15 °C e máxima de 28 °C (Godoy et al., 2021). Segundo o Instituto Nacional de Meteorologia (INMET), em 2022 o estado de São Paulo marcou o volume de chuva anual de 1.483,4 mm. A estação mais seca ocorre entre abril e setembro, com média de chuvas de 2 mm/dia, tendo uma temperatura média mínima de 14°C e máxima de 24°C (Godoy et al., 2021). Segundo a classificação Köppen para a região, o município de Cordeirópolis se classifica como “Cfa” (Rolim et al., 2007). A categoria “Cfa” é caracterizada por temperaturas aproximadas a 22 °C; e de acordo com a pluviometria, a área mostra um constante excedente hídrico entre setembro e março, e déficit hídrico entre abril e agosto (Rolim et al., 2007). Segundo CPRM (2017), a precipitação média anual entre os anos de 1977 e 2006 foi de 1.500 mm. A média mensal do mês de agosto, mês escolhido para este trabalho de campo, é de 37,5 mm.

Segundo a carta de suscetibilidade de Cordeirópolis, publicada pela CPRM em 2017, as áreas úmidas, cabeceiras de drenagem e margens de rios são caracterizadas como uma região com alta suscetibilidade à inundação. O interessante dessas regiões com alta suscetibilidade a inundação para esse trabalho é que abrange as depressões fechadas, caracterizadas como mal drenadas, apresentam o nível de lençol freático aflorante a muito raso, as quais são encontradas em planícies de inundações com a declividade menor de 5° e com presença de solos hidromórficos (CPRM, 2017).

Figura 6 – Mapa de localização do município de Cordeirópolis no estado de São Paulo e aspecto geral da área úmida estudada.



Fonte: Autora, 2024

Do ponto de vista geológico, as unidades encontradas no território municipal são Serra Geral, Corumbataí, Tatuí, Irati, Itacaré, Pirambóia e Rio Claro (Vieira e Vieira, 2019). A litologia do município é composta por Arenito, Diamictito, Folhelho, Ritmito, Calcário, Cascalho, Areia, Argila, Lamito, Diábasio, Arenito-Fino, Arenito Siltico-argiloso, Siltito, Arenito e Argilito (CPRM, 2017). Segundo Vieira e Vieira (2019), a unidade geológica de maior predominância em Cordeirópolis é a Serra Geral. Na Figura 7 encontra-se o esquema de classificação estratigráfica da microrregião de Santa Gertrudes. A microrregião de Santa Gertrudes e a microrregião de Limeira pertencem à mesorregião de Piracicaba.

Figura 7 – Coluna Estratigráfica da região de estudo.

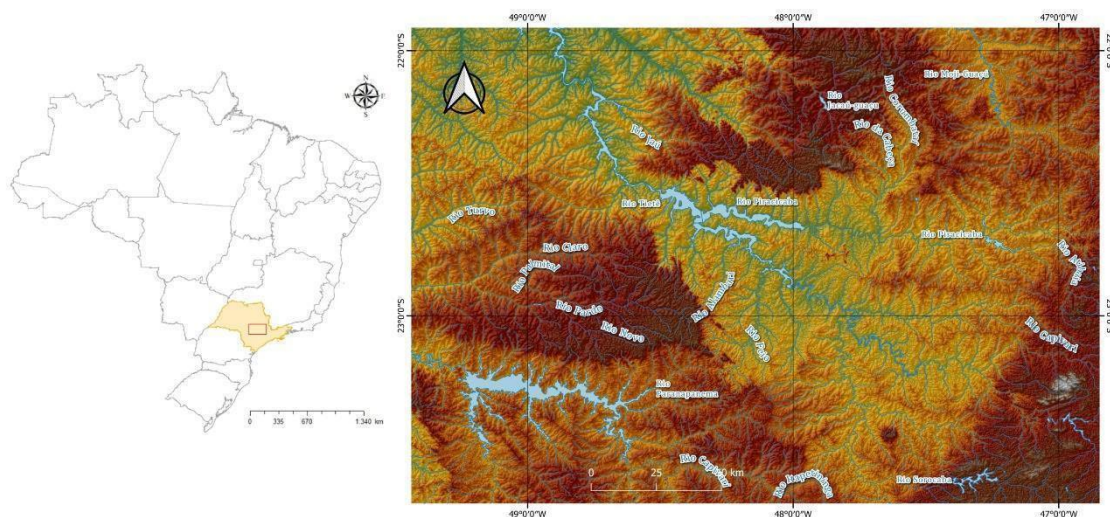
Era	Períodos	Grupo	Formação	Litologia	I metros	Descrição	Ambiente de Deposição
Cenozoica	Neógeno		Rio Claro		30	Arenitos pouco consolidados com lentes de argila e níveis conglomeráticos na base.	Continental: planície aluvial e lacustre, coluviões.
	Paleógeno		Itaqueri		100	Arenitos conglomeráticos e arenitos silicificados/ferricretes.	Continental: leques aluviais.
Mesozoica	Cretáceo	São Bento	Serra Geral		100	Derrames de basalto com lentes de arenito na base, diques e soleiras de diabásio.	Magmatismo fissural.
			Botucatu		100	Arenitos bem selecionados com grãos bem arredondados e esféricos, pouca argila.	Continental: desértico.
	Jurássico		Pirambóia		150	Arenitos arredondados e esféricos, diversos níveis de lamitos.	Continental: fluvial e desértico.
	Triássico		Corumbataí Topo		100	Siltitos contendo lentes de arenito fino, arenitos, siltitos, arenitos finos, níveis de calcários dolomíticos e coquinas.	Continental: lacustre e planície de maré.
Paleozoica	Permiano	Passa Dois	Corumbataí Base		40	Folhelhos, siltitos, folhelhos pirobetuminosos e calcários dolomíticos.	Laguna e plataforma.
			Irati		50	Siltitos e siltitos arenosos.	Planície costeira e plataforma.
			Tatuí		900	Arenitos, siltitos, varvitos e diamictitos.	Continental: glacial, fluvial e lacustre.
	Triássico	Itararé	«Indiviso»			Granitos, migmatitos, gnaisses, xistos e quartzitos.	Marinho e glaciomarinho.
			Embasamento			Granitos, migmatitos, gnaisses, xistos e quartzitos.	
Pré-Cambriano							

Fonte: ROVERI, 2010 apud CPRM, 2014. p.21

O ambiente sedimentar pode apresentar fácies arenosas e argilo-siltosas. No município de Cordeirópolis especificamente a formação Corumbataí ocorre em conjunto com diques de diabásio da formação Serra Geral (CPRM, 2005). A configuração do relevo do município varia entre várzeas, rampa de alúvio-colúvio, formações tecnogênicas, colinas, morros baixos, morros altos e feições cársticas (CPRM, 2017)

Esses elementos fazem parte de um subcompartimento referente à depressão de Mogi-Guaçu, depressão do Médio-Tietê e depressão do Paranapanema (Ross e Moroz, 1997), presentes em todas as bacias hidrográficas da região. De acordo com Penteado (1983) e Pinheiro (2014), as principais bacias hidrográficas da depressão no cinto periférico em São Paulo são Paranapanema, Tietê, Mogi-Guaçu e Pardo.

Figura 8 – Mapa Hipsométrico Regional, ALOS DSM: Global 30m.

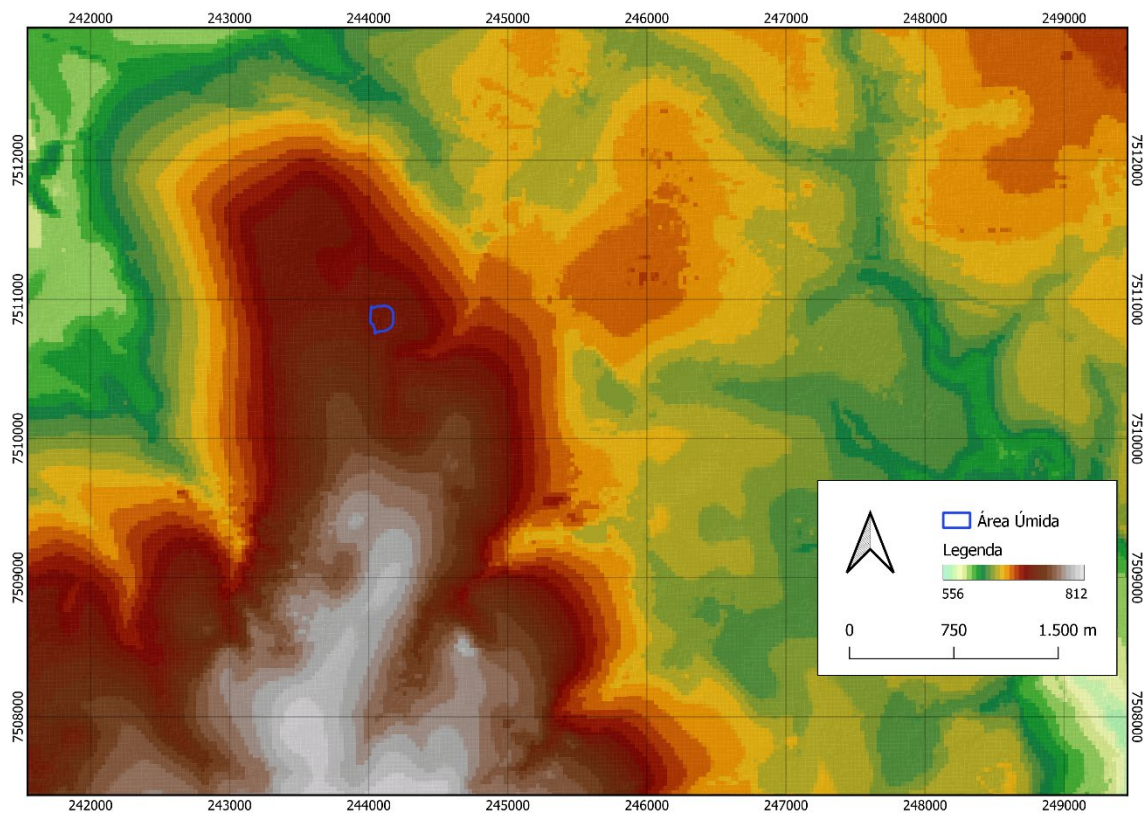


Fonte: GEE, 2024.

No município de Cordeirópolis encontra-se a sub-bacia do Jaguari e a sub-bacia do Corumbataí, onde está localizada a área úmida. Os solos principais na região são Latossolo vermelho, Latossolo vermelho amarelo, Gleissolo e Argissolo (Vieira e Vieira, 2019).

A topografia do município de Cordeirópolis varia entre 600 e 800 m, e a declividade ao entorno da área úmida varia entre 2 a 5% (CPRM, 2017). Segundo o modelo de elevação digital global Copernicus DEM - GLO-30, com a resolução de 30 metros, a elevação da região com a área úmida está especificamente posicionada no patamar de 700 m (Figura 9).

Figura 9 – Mapa Hipsométrico da Área de Estudo.



Fonte: Copernicus, 2023.

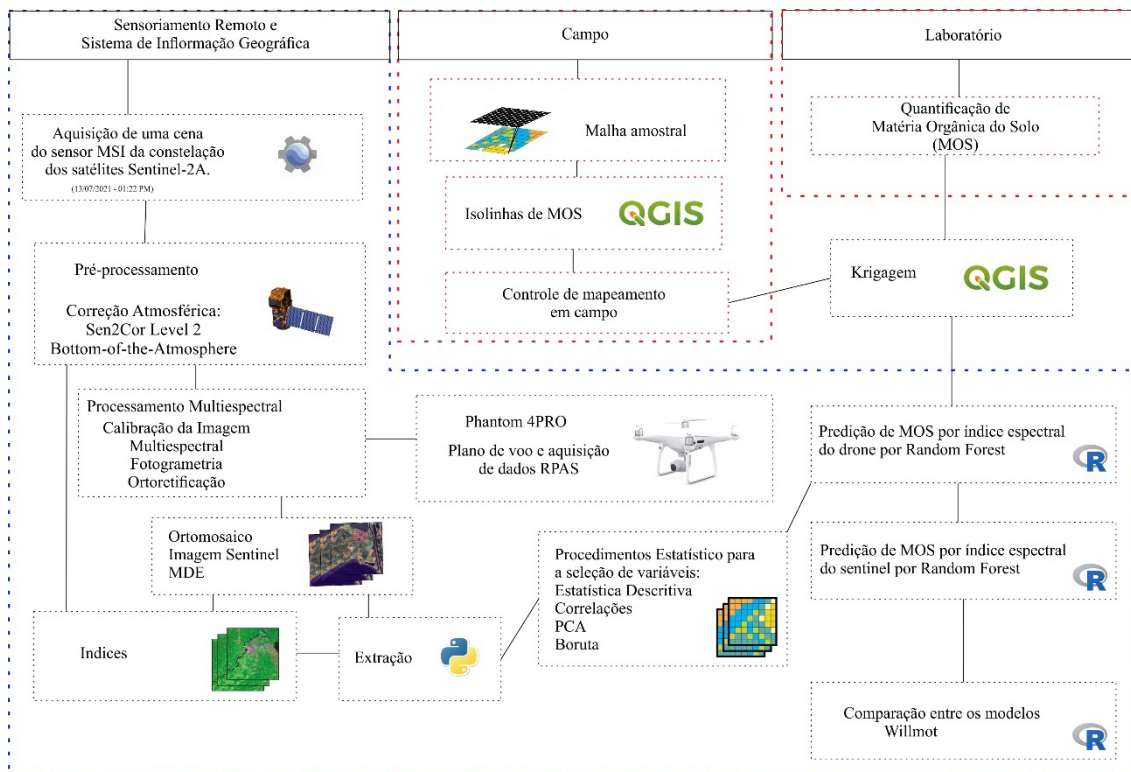
O bioma encontrado no município segundo IBGE (2023) é a Mata Atlântica, contudo, sustenta-se que a região seja um ecótono entre Cerrado e Mata Atlântica (Souza et al., 2012). Os aspectos regionais são caracterizados como um mosaico vegetacional que atravessa o estado de São Paulo, como uma faixa iniciando na região nordeste do estado, passando pelo centro, e alcançando o extremo sudeste do estado. Ambos os biomas estão atrelados à problemática ambiental causada pelo desmatamento que ocorreu ao longo do século XX no estado de São Paulo.

As áreas de preservação permanente em Cordeirópolis/SP apresentam sinais de degradação devido à expansão urbana, práticas agrícolas intensivas e falta de vegetação nativa (Cassiano, 2013; Alves, 2022). Uma questão marcante neste cenário foi o rápido desenvolvimento do setor sucroalcooleiro no estado de São Paulo, que pode agravar os impactos ambientais, incluindo a degradação das APPs e RL, assoreamento e contaminação de corpos d'água, ressaltando a necessidade de melhoria no manejo sustentável (Tosto et al., 2011).

## 2.2. Procedimentos metodológicos

As etapas e os procedimentos metodológicos realizados neste trabalho estão organizados no fluxograma da Figura 10.

Figura 10 – Fluxograma das etapas metodológicas para execução de modelos preditivos.



Fonte: Autora, 2023.

### 2.2.1. Obtenção e tratamento das imagens orbitais e aéreas

A presente pesquisa foi realizada utilizando duas plataformas imageadoras, sendo a primeira de base satelitária, o Sentinel-2A, e a segunda de base aérea, o Remotely Piloted Aircraft System (RPAS) Phantom 4 PRO.

O satélite Sentinel-2A da Agência Espacial Europeia (ESA, 2022) possui o sensor multiespectral MSI, que disponibiliza 13 bandas. Neste trabalho de pesquisa foram utilizadas as 4 bandas espectrais, que possuem resolução espacial de 10 metros, conforme demonstrado na Tabela 1.

Tabela 1 - Características das bandas de interesse geradas pelo instrumento MSI.

Satélite*	Sensor	Bandas	Resolução	Resolução
			Espectral	Espacial
Sentinel-2A	MSI	Azul (Banda 2)	490nm	10m
		Verde (Banda 3)	560nm	10m
		Vermelho (Banda 4)	665nm	10m
		Infravermelho	842nm	10m
		Próximo (Banda 8)		

Data de aquisição \* Sentinel-2A: 13/07/2021

Fonte: Agência Espacial Europeia (ESA).

Os dados de imagens de satélite foram obtidos na plataforma Google Earth Engine da coleção Copernicus, especificamente do satélite Sentinel-2A. A imagem do Sentinel-2A é disponibilizada previamente processada, ou seja, os valores dos *pixels* são disponibilizados com correção atmosférica e os valores de radiância já transformados para reflectância, ambos calculados a partir da posição e ângulo do sensor. Esses fatores fazem com que os valores de reflectância tenham maior acurácia radiométrica, característica importante para estudos com maior detalhamento.

A plataforma Google Earth Engine contém essa coleção de imagens e ferramentas de *machine learning* que seleciona as imagens com menor interferência das nuvens dentro da janela temporal de interesse, que neste estudo foi a média do mês em que foi realizada a coleta em campo. A partir dessas imagens do Sentinel-2A, foi realizado o cálculo dos índices espectrais para a área de estudo por meio do cálculo de bandas espectrais no Google Earth Engine (Tabela 2).

Tabela 2 - Fórmulas dos índices espectrais Sentinel-2A utilizados e referências.

<b>NDVI</b>	Normalized Difference Vegetation Index	$\frac{NIR - RED}{NIR + RED}$	$\frac{B8 - B4}{B8 + B4}$	Rouse et al., 1973 Rouse et al., 1974 Russell Main, 2011
<b>SBIMSS</b>	Soil Brightness Index	$0,332 * GREEN + 0,603 * RED + 0,675 * REDedge2 + 0,262 * Water\ vapor$	$0,332 * B3 + 0,603 * B4 + 0,675 * B6 + 0,262 * B9$	Kauth, 1976
<b>SAVI</b>	Soil-Adjusted Vegetation	$\frac{(NIR - RED)}{(NIR + RED + L)} * (1 + L)$	$\frac{(B8 - B4)}{(B8 + B4 + L)} * (1 + L)$	Huete, 1988
<b>MSI</b>	Moisture Stress Index	$\frac{SWIR\ 1}{NIR}$	$\frac{B11}{B8}$	Hunt, 1989

<b>EXG</b>	Excess Green Index	$2 * GREEN (RED + BLUE)$	$2 * B3 - (B4 + B2)$	Woebbecke et al., 1995
<b>OSAVI</b>	Optimized Soil Adjusted Vegetation	$\frac{NIR-RED}{NIR+RED+L} * (1 + L)$	$\frac{B8 - B4}{B8 + B4 + L} * (1 + L)$	Rondeaux et al., 1996
<b>GVM</b>	Global Vegetation Moisture Index	$\frac{(NIR + 0,1) - (SWIR + 0,02)}{(NIR + 0,1) + (SWIR + 0,02)}$	$\frac{(B8 + 0,1) - (B11 + 0,02)}{(B8 + 0,1) + (B11 + 0,02)}$	Gleem, 2010 Ceccato, 2002
<b>SOIL</b>	Soil Composition Index	$\frac{SWIR 1 - RED}{SWIR 1 + RED}$	$\frac{B11 - B4}{B11 + B4}$	Khaier, 2003
<b>Fe iron</b>	Ferric Iron	$\frac{RED}{GREEN}$	$\frac{B4}{B3}$	Rowan, 2003
<b>Ferrous</b>	Ferrous	$\frac{SWIR 2}{SWIR 1}$	$\frac{B12}{B11}$	Rowan, 2003
<b>Fe</b>	Ferric	$\frac{SWIR 2}{NIR} + \frac{GREEN}{RED}$	$\frac{B12}{B8} + \frac{B3}{B4}$	Rowan, 2003
<b>Clay</b>	Clay	$\frac{SWIR 1}{SWIR 2}$	$\frac{B11}{B12}$	Dogan, 2009
<b>VARI</b>	Visual Atmospheric Resistance	$\frac{GREEN - RED}{GREEN + RED - BLUE}$	$\frac{B3 - B4}{B3 + B4 - B2}$	Ahamed, 2011 Gitelson, 2003 Gitelson, 2002

Fonte: Autora, 2024

Os dados de imagens aéreas foram obtidos por meio de imageamento com o drone *PHANTOM 4 PRO*, acoplado com sensor CMOS, com bandas RGB (Tabela 3). O voo foi realizado em agosto de 2021, empregando o *software* de plano de voo *Pix4DCapture*. O imageamento foi realizado em período anterior a esta pesquisa, por uma equipe de pesquisadores da UNESP, e o processamento das fotos aéreas realizado no *software Agisoft Metashape*.

Tabela 3 - Características das bandas de interesse geradas pelo instrumento Phantom 4 PRO.

Satélite*	Sensor	Bandas	Resolução Espectral	Resolução Megapixels
Phantom 4	CMOS	Azul (Banda 1)	434 - 466 nm	20M
		Verde (Banda 2)	544 - 576 nm	20M
		Vermelho (Banda 3)	634-666 nm	20M

Data de aquisição \*RPAS: 13/08/2021

Fonte: Autora, 2024

Após o processamento das imagens do RPAS, foram realizados os cálculos dos índices espectrais RGB a partir das imagens do *Phantom 4 Pro* utilizando o *plugin ArcPy* (Tabela 4).

Tabela 4 - Fórmulas do índices espectrais RPAS utilizados e referências.

<b>CIVE</b>	Color index of vegetation extraction	$(0,441*RED) - (0,881*GREEN) + (0,385*BLUE) + 18,78745$	$(0,441 * B4) - (0,881 * B3) + (0,385 * B2) + 18,78745$	Poley et al., 2020
<b>RG</b>	Simple Ratio SR672/550	$\frac{RED}{GREEN}$	$\frac{B4}{B3}$	Aslan et al., 2022 Segarra et al., 2020
<b>EXG</b>	Excess green index	$2 * GREEN - RED - BLUE$	$2 * B3 - B4 - B2$	Woebbecke et al., 1995
<b>EXR</b>	Excess-red index	$1.4 * RED - GREEN$	$1.4 * B4 - B3$	Atzberger et al., 2015
<b>EXGR</b>	Excess green-excess red	$EXG - EXR$	-	Meyer; Neto., 2008
<b>GLI</b>	Green Leaf Index	$\frac{2GREEN - RED - BLUE}{2GREEN + RED + BLUE}$	$\frac{2B3 - B4 - B2}{2B3 + B4 + B2}$	Zhang et al., 2021
<b>MGVRI</b>	Modified Green Red Vegetation Index	$\frac{GREEN^2 - RED^2}{GREEN^2 + RED^2}$	$\frac{B3^2 - B4^2}{B3^2 + B4^2}$	Bendig et al., 2015
<b>MPRI</b>	Modified Photochemical Reflectance Index	$\frac{(GREEN - RED)}{(GREEN + RED)}$	$\frac{(B3 - B4)}{(B3 + B4)}$	Tucker, 1979
<b>NGBDI</b>	Normalized green-red difference index	$\frac{(GREEN - BLUE)}{(GREEN + BLUE)}$	$\frac{(B3 - B2)}{(B3 + B2)}$	Hunt et al., 2005
<b>RGBVI</b>	Red-green-blue vegetation index	$\frac{(GREEN^2 - RED * BLUE)}{(GREEN^2 + RED * BLUE)}$	$\frac{(B3^2 - B4 * B2)}{(B3^2 + B4 * B2)}$	Poley et al., 2020
<b>RGVBI</b>	Red Green Blue Vegetation Index	$\frac{(GREEN - (BLUE * RED))}{(GREEN^2 + (BLUE * RED))}$	$\frac{(B3 - (B2 * B4))}{(B3^2 + (B2 * B4))}$	Bendig et al., 2015
<b>TGI</b>	Triangular greenness index	$GREEN - 0,39 * RED - 0,61 * BLUE$	$B3 - 0,39 * B4 - 0,61 * B2$	Hunt Jr et al., 2011
<b>VARI</b>	Visible Atmospherically Resistant Index	$\frac{(GREEN - RED)}{(GREEN + RED - BLUE)}$	$\frac{(B3 - B4)}{(B3 + B4 - B2)}$	Rouse, 1974
<b>DAVI</b>	Daylight Adapted Vegetation Index	$\frac{GREEN}{RED^{0.667} - BLUE^{1-0.667}}$	$\frac{B3}{B4^{0.667} - B2^{1-0.667}}$	Hague et al., 2006
<b>NDI</b>	Normalized Difference Index (NDI)	$128 * \frac{GREEN - RED}{GREEN + RED} + 1$	$128 * \frac{B3 - B4}{B3 + B4} + 1$	Woebbecke et al., 1992
<b>CI</b>	Coloration Index	$\frac{RED - BLUE}{RED}$	$\frac{B4 - B2}{B2}$	Henrich e Krauss, 2021

Fonte: Autora, 2024


### 2.2.2. Atividade de Campo

O trabalho de campo foi realizado entre os dias 15/09/2022 e 18/09/2022. As coletas de solo foram realizadas utilizando trado holandês. Em campo, foi estabelecido que a

amostragem seria realizada segundo ordenamento alfabético para as linhas e numérico para as colunas, conforme figura 11.

Para o trabalho de coleta, foi definida uma malha amostral contendo pontos separados por uma distância de 20 m, conforme proposta de amostragem regular proposta por e Landim, 2015). Os pontos foram gerados automaticamente, através dos *pixels* da imagem Sentinel-2A, pelo *software* Qgis utilizando a ferramenta *Raster to point*. As amostras de solo foram coletadas da superfície até 15 cm de profundidade, para que os dados representassem o teor de MOS da primeira camada do solo. As amostras foram devidamente armazenadas em sacos plásticos e nomeadas (EMBRAPA, 2011).

Figura 11 - Malha amostral das coletas realizadas em campo.



Fonte: Autora, 2023.

### 2.2.3. Atividades de Laboratório

Todas as amostras foram inicialmente colocadas para secar ao ar livre; quando secas, foram destorroadas e peneiradas em peneiras 2 mm, obtendo-se a Terra Fina Seca ao Ar (TFSA). O método aplicado no laboratório Solocria é uma adaptação do Manual de métodos de análise de solo (EMBRAPA 2011, 2016), onde a determinação consiste em: I) Medir 1 mg de T.F.S.A. de cada amostra e transferir para um coletor de 80 ml. II)

Adicionar 10 ml de NaCrO em H<sup>2</sup>SO<sup>4</sup>. III) Colocar para agitar em um agitador circular horizontal durante 10 minutos. IV) Colocar para repouso por 1 hora. V) Adicionar 50 ml de água e agitar. VI) Colocar para repouso por 12h – 14h. VII) Transferir o sobrenadante de cada amostra para um tubo de ensaio. VIII) Fazer a leitura da solução padrão. IX) Transferir as amostras para um tubo de ensaio do calorímetro e fazer as leituras das amostras através do espectrofotômetro de chama. X) Através do dado de matéria orgânica é realizado um cálculo, para aferir a quantidade de carbono.

#### 2.2.4. Espacialização da MOS obtida em campo por Krigagem

A espacialização dos dados de matéria orgânica do solo foi realizada a partir do método geoestatístico denominado Krigagem (Yamamoto e Landim, 2013). A ferramenta Krigagem oferece como resultado uma superfície interpolada de valores de matéria orgânica do solo, a partir dos pontos de amostragem. Na prática, este método de interpolação constrói um semivariograma, a partir da semivariância dos pontos amostrais, estimando a curva que mais se aproxima do variograma construído.

A equação 1 representa a etapa da média aritmética, onde  $n$  é o número de dados e  $x_n$  são os valores dos dados.

Equação 1 - Média

$$m = \frac{1}{n} \sum_{i=1}^n x_i$$

Fonte: ISAAKS et al., (1989, cap. 2, p. 17).

A equação 2 representa a variância, que evidencia a flutuação dos dados em relação à média, onde  $n$  é o número de dados,  $x_n$  são os valores do conjunto dos dados,  $x_i$  é um valor individual e  $m$  é a média dos valores dos dados. É relevante apontar que os valores *outliers* ou anômalos interferem significativamente, devido a excepcionalidade da amplitude da variação.

Equação 2 - Variância

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$$

Fonte: ISAAKS et al., (1989, cap. 2, p. 20).

A equação 3 representa covariância, que aponta o padrão das duas variáveis  $x$  e  $y$  em relação às suas médias. E ela é influenciada pela magnitude dos dados; por isso, a covariância deve ser dividida pelo desvio padrão, garantindo que estejam normalizados.

Equação 3 - Covariância

$$C_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - m_x)(y_i - m_y)$$

Fonte: ISAAKS et al., (1989, cap. 3, p. 30).

A equação 4 representa a fórmula teórica do semivariograma da dispersão ( $h$ ), que está diretamente ligada com a direção que essas variáveis contínuas foram especializadas. Nessa fórmula existe uma separação entre os  $N(h)$ , sendo a distância entre eles, de forma aproximada, os valores de  $h$ . Essa metodologia admite uma distância e direção aproximadas.

Equação 4 - Dispersão para variáveis contínuas e especializadas

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i,j|h_{ij}=h} (v_i - v_j)$$

Fonte: ISAAKS et al., (1989, cap. 3, p. 60, p. 142).

A equação 5 representa a krigagem média simples, utilizando a média dos dados coletados para espacializar a variável de forma local, inferindo apenas nas regiões não amostradas vizinhas às coletas. A frequência amostral conduz a estimativa logarítmica, sendo denominada também krigagem lognormal.

Equação 5 – Krigagem ordinária

$$\hat{Z}(X_0) = \sum_{i=1}^n \lambda_i Z(x_i)$$

Fonte: YAMAMOTO e LANDIM, (2013, cap. 3, p. 95).


Nesta pesquisa foi utilizado o processo de Krigagem universal ordinária com a realização de testes para verificar qual o modelo de krigagem (linear, exponencial, esférico e gaussiano) mais se adequava aos dados de matéria orgânica no solo. Foram utilizadas as ferramentas de calibração de krigagem (*partial fill e nugget*) para obter o melhor ajuste da curva de krigagem e escolha do método com menor RMSE. Todos os procedimentos da Krigagem foram realizados no software *ArcGis*.

## 2.2.5. Tratamento estatístico de variáveis de Sensoriamento Remoto

### 2.2.5.1. Extração das variáveis espectrais

As variáveis espectrais dos dados obtidos do Sentinel-2A e do RPAS foram extraídas com o uso do *software* ArcGis. A extração foi gerada a partir de uma grade de 12,5 x 12,5 ao redor de cada ponto de coleta, gerada com o uso da ferramenta *buffer* no *Software* Qgis (Figura 12). O método permite a criação de um banco de dados espectrais, que refletem a interação espectral do entorno da área de coleta de MOS e os dados de teor de MOS obtidos em campo e medidos em laboratório. O processo de extração dos valores espectrais médio e mediano no interior do *buffer* foi realizado com o uso da ferramenta *Zonal Statistics*.

Figura 12 - Malha de extração das variáveis espectrais.



Fonte: Autora, 2024.

### 2.2.5.2. Estatística descritiva dos dados espectrais e de krigagem

A estatística descritiva dos dados espectrais do Sentinel-2A e RPAS foi realizada pelo cálculo dos valores mínimo, média, máximo e desvio padrão dos dados dos *pixels* de todas as bandas utilizadas. Para melhorar a visualização espacial e dos valores espectrais, foram colocados junto aos mapas *boxplots* e histogramas de acordo com as classes definidas no mapa.

Também foi realizada a estatística de correlações simples entre os índices espectrais (RPAS e do Sentinel-2A), com variável dependente MOS, com objetivo de verificar se existem relações lineares positivas, negativas ou sem correlação significantes entre as variáveis espectrais e do Sentinel-2A com MOS. A construção de todas as etapas do método descritivo foi realizada no software R, por meio dos pacotes disponíveis gratuitamente, como *dplyr*, *lubridate*, *ggplot2*, *tidyverse*.

### 2.2.5.3. Seleção de variáveis de dados espectrais em relação à MOS

A confecção de um modelo preditivo de MOS na área de pesquisa envolveu a seleção de variáveis espectrais (Sentinel-2A e RPAS) com potencial para explicar a distribuição da variável dependente (MOS) no interior da pequena área úmida e seu entorno. Nesta fase, inicialmente, foram empregados o algoritmo de análise de componentes principais (ACP) e o algoritmo baseado em *Random Forest* denominado Boruta. Ambos os processos foram realizados no *software* RStudio.

O primeiro método para seleção de variáveis foi a Análise de Componentes Principais (ACP), que reduz a dimensionalidade de um conjunto de dados. A ACP é uma estatística de análise multivariada que tem o objetivo de reduzir o número de variáveis originais por outro conjunto de dados em eixos ortogonais não correlacionados, com a menor perda possível de informação (Mirsha et al., 2017). Esta fase consiste em identificar qual combinação de variáveis possui o maior potencial para explicação dos índices espectrais que explicam a distribuição da MOS.

Neste trabalho, na análise de componentes principais, foram inseridas as variáveis espectrais (satélite/RPAS) para identificação dos índices com maiores contribuições no “ACP1, ACP2, ...” e a MOS foi implementada na ACP como variável suplementar quantitativa.

O segundo método da escolha das variáveis foi procedido com o uso do *software* RStudio, pelo algoritmo Boruta. O método utiliza Random Forest ou árvore de decisão (Kursa e Rudnicki et al., 2010). A seleção das variáveis pelo Boruta já foi utilizada para predição de carbono para grandes regiões, como no trabalho de Boulihim et al., (2024). Essa ferramenta foi utilizada para realizar a seleção das variáveis entre os índices espectrais tendo a MOS como variável alvo. Foram utilizados os pacotes instalados em ambiente R, *readxl*, *boruta*, *caret* e *ggplot2*. A fim de processar esses dados no Boruta,

foram removidas as variáveis espectrais que se mostraram com menor potencial de estimar MOS ao rodar o ACP.

A implementação do algoritmo Boruta realiza interações para determinar quais as variáveis possuem maior importância estatisticamente em relação à variável alvo. O Boruta gera como produtos gráficos as variáveis de maior variância em relação com a variável alvo e as variáveis espectrais.

O modelo de árvore de decisão permite que se treine o algoritmo através do pacote *caret* com as variáveis confirmadas pelo Boruta. A avaliação da importância das covariáveis calcula a importância das variáveis no modelo de árvore de decisão treinado e a verificação dessas variáveis ocorre pela seleção das variáveis com importância de um limiar determinado pelo modelo, que neste caso é inferido de uma mediana.

#### **2.2.5.4. Classificação e acurácia dos modelos gerados pelos índices espectrais orbitais e RPAS.**

Após a seleção de variáveis espectrais (Sentinel-2A e RPAS) mais significativas relacionadas à MOS, foi procedida a classificação da MOS. Esta fase também foi realizada com o uso do classificador algoritmo Random Forest, disponível no *software* RStudio. O RF realiza análise espacial e aprendizado de máquina para prever valores de MOS baseados em índices espectrais derivados de imagens de RPAS e satélite. Este procedimento estatístico cria múltiplas árvores de decisão de maneira aleatória, formando uma “floresta” onde cada árvore contribui para o resultado através de uma votação, aumentando a precisão da medição (Breiman, 2001).

Para a medição da matéria orgânica do solo (MOS) na área de estudo, a partir dos índices espectrais dos dados Sentinel-2A e RPAS, foi utilizado igualmente o algoritmo Random Forest. Como medida de acurácia dos índices dos modelos de predição de matéria orgânica no solo (MOS) por meio dos índices espectrais, foram empregadas medidas de acurácia, coeficiente de determinação ( $R^2$ ) e erro quadrático médio (RMSE). O método de acurácia dos modelos implementados nos índices Sentinel-2A e RPAS revelam o nível de confiabilidade dos modelos gerados pela Classificação Random Forest.

#### **2.2.6. Comparação dos modelos de predição de MOS**

A análise comparativa dos modelos de predição de MOS utilizando os *rasters* de krigagem, Sentinel-2A e RPAS foi realizada no *software* RStudio, permitindo a

comparação espacial dos valores de MOS gerados nos modelos. Inicialmente, os *rasters* foram reamostrados para uma resolução de 20 m, a fim de possibilitar a comparação entre os modelos com diferentes resoluções.

Na primeira etapa, foram gerados gráficos de dispersão para comparar os pares de dados krigagem (MOS do solo em campo) x Sentinel-2A; krigagem (MOS do solo em campo) x RPAS; e Sentinel-2A x RPAS. Esses gráficos permitiram a visualização da relação linear entre os conjuntos de dados, possibilitando a avaliação da concordância e semelhança entre as diferentes fontes e plataformas de dados, sejam elas provenientes do solo (krigagem), orbital (Sentinel-2A) ou aérea (RPAS). A partir do gráfico de dispersão, foi possível realizar a análise de correlação, sendo calculados indicadores de desempenho, como o coeficiente de determinação ( $R^2$ ), a correlação e o índice de concordância de Willmott. Na segunda etapa, a distribuição dos valores de MOS foi analisada por meio de histogramas, permitindo verificar a distribuição dos valores de MOS para cada conjunto de dados.

#### **2.2.7. Estudo do uso da terra no entorno da área úmida**

A área úmida estudada neste trabalho é pequena e está circundada por cana-de-açúcar, tornando pertinente verificar o histórico do uso para auxiliar na interpretação dos dados sobre a MOS. Para melhor compreensão das atividades desenvolvidas no entorno da área úmida, foi feita breve pesquisa bibliográfica e levantado o uso da terra no município de Cordeirópolis do ano de 1985 ao ano de 2023. Esse levantamento foi feito a partir dos produtos do MapBiomias e de imagem Sentinel-2A, a mesma utilizada para a determinação dos índices espectrais acima referidos. As classificações disponíveis pelo Mapbiomas utilizam a imagem Landsat como arquivo base (SOUZA et al., 2020).

É relevante mencionar que, nos produtos do MapBiomias, o nível de detalhamento das classes de uso da terra aumentou progressivamente desde as primeiras imagens disponíveis até os dias atuais. Nas representações gráficas geradas, cada classe tem uma cor geral e essa classe geral representa um conjunto de subclasses mais específicas. É relevante mencionar que, nos produtos do MapBiomias, o nível de detalhamento das classes de uso da terra aumentou progressivamente desde as primeiras imagens disponíveis até os dias atuais. Apesar do pequeno número de classes dos produtos mais antigos em relação aos atuais, a cada ano é feita uma atualização do produto. Ou seja, à medida que os sensores se atualizam e ganham resolução, anualmente o mapbiomas

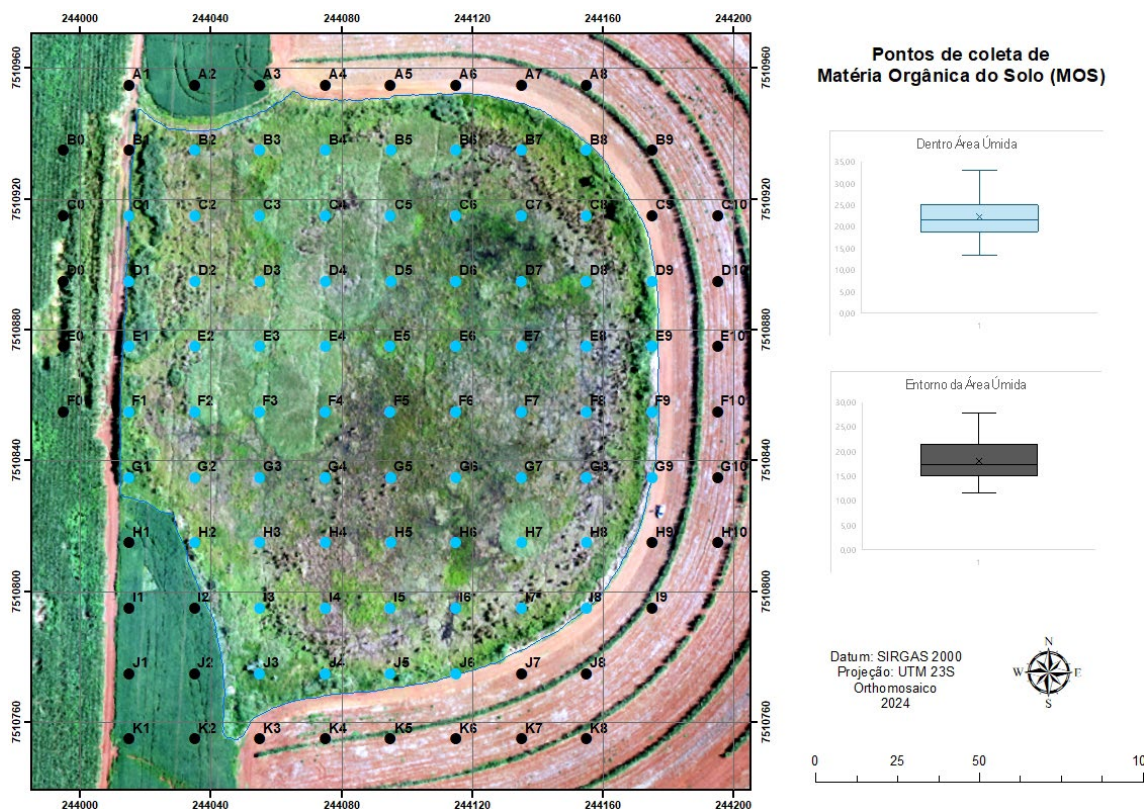
atualiza a sua chave de classificação, criando novas classes quando necessário, desta forma não perdendo as possibilidades de comparações com os dados das classes mais gerais, produzidos com as resoluções das imagens dos anos 80 e 90. Os dados utilizados para compreender a distribuição das classes do uso da terra e para compreender a mudança e conversão do uso da terra no município ao longo dos anos foram utilizados nos anos 2000, 2010, 2020 e 2023, utilizando como fonte os dados gratuitos disponibilizados anualmente na plataforma Mapbiomas, coleção 8.

### 3. Resultados

#### 3.1. Distribuição e espacialização do teor de MOS da área úmida

A Figura 13 ilustra os pontos de coleta das amostras de solo em campo e os *boxplots* com o teor de MOS para a parte interior da área úmida (azul) e para seu entorno (marrom).

Figura 13 – Pontos de coleta e *boxplot* do teor de MOS para o interior e o entorno da área úmida.



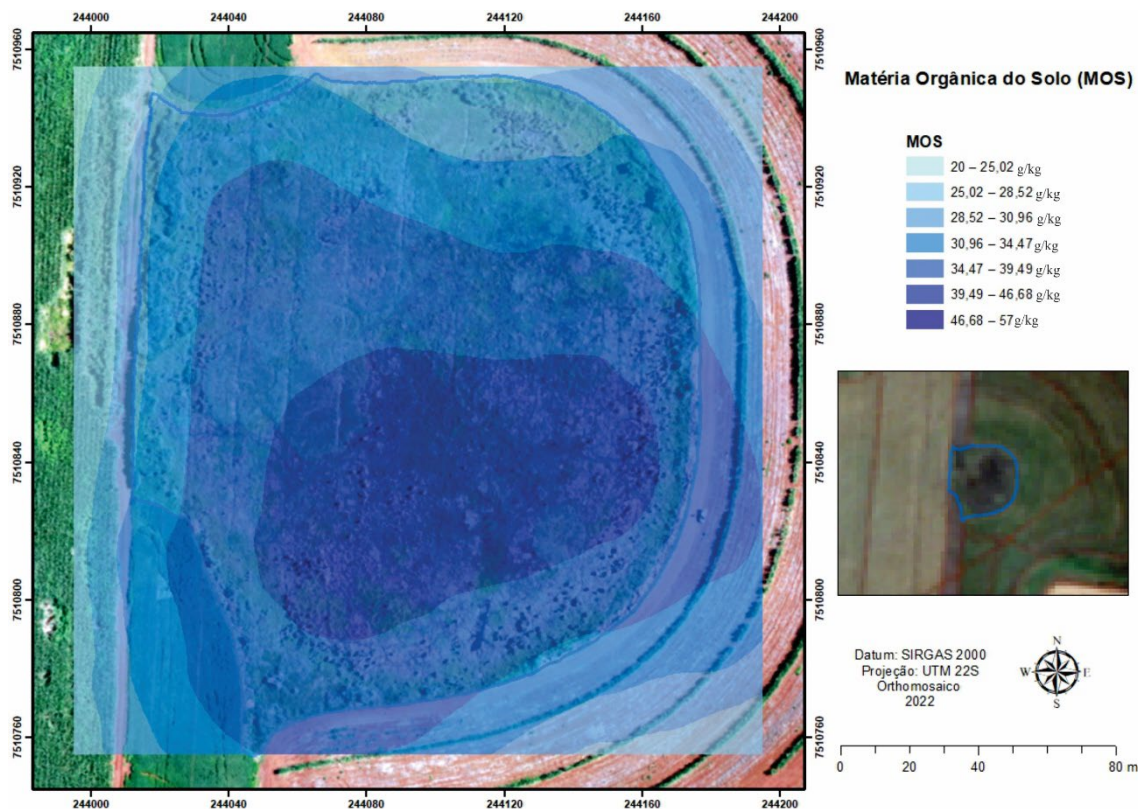
Fonte: Autora, 2024.

À medida que as primeiras observações foram feitas sobre a distribuição de valores de MOS na área de estudo, evidencia-se um padrão de concentração no interior da área com maior concentração de vegetação. A parte externa da área úmida, no contato com as áreas de cultivo agrícola, possui menor concentração de MOS. A comparação de valores de concentração de MOS no interior da área úmida e no seu exterior indica esse padrão, mínimo (23 g/kg – 20 g/kg), máximo (57 g/kg – 48 g/kg), mediana (38,54 g/kg – 30,38 g/kg) e o desvio padrão (7,52 g/kg - 6,11 g/kg).

Na segunda abordagem de distribuição da MOS na área do estudo, tendo como ponto de partida a geostatística krigagem, verifica-se que a ocorrência de zonas

concêntricas de valores de MOS menores no lado externo da área úmida e um progressivo aumento do lado interno da Área Úmida. Verifica-se na (Figura 14) que os maiores teores em MOS se concentram na parte sul do interior da área úmida, indicando uma configuração assimétrica; a parte externa possui valores na faixa de 20 g/kg e a parte mais interna cerca de 57 g/kg.

Figura 14 – Mapa da distribuição de Matéria Orgânica do Solo.



Fonte: Autora, 2024

A tabela 5 apresenta os resultados da krigagem ordinária universal realizada para os 107 (cento e sete) amostras da área de pesquisa.

Tabela 5 – Estatística descritiva dos dados de MOS.


<b>Estatística</b>	<b>Valor</b>
Número	107
Média	0,4066
Média normalizada	0,0526
Root-Mean-Square	7,22
RMS normalizado	1,04
Erro médio normalizado	6,94

Fonte: Autora, 2024.

Os parâmetros estatísticos da Krigagem Ordinária Universal do conjunto de dados de coleta de solo das 107 amostras, permitiu a avaliação estatística dos parâmetros espaciais da distribuição da variável. A média dos resíduos calculada em 0,4066, indica uma leve subestimação dos valores de MOS. O valor do RMS foi de 7,22 para mais ou para menos. A média normalizada dos resíduos é 0,0526 e o RMS normalizado apresentou o valor de 1,04 confirmam uma boa adequação do modelo na dispersão dos erros. Este resultado é congruente com um modelo que, apesar de apresentar um viés de subestimação, tem uma distribuição centrada de erros quando ajustada pelo erro padrão.

A figura 15 apresenta o semivariograma da krigagem da matéria orgânica. Ela indica que, de forma geral, foi possível um bom ajuste da curva pelo método *hole effect*.

Figura 15 – *Kriging step*, Semivariograma do Modelo de Covariância.




Fonte: Autora, 2024

Os pontos vermelhos representam a semivariância calculada para cada par de amostras de MOS em diferentes distâncias, refletindo a variabilidade geoespacial. Os pontos azuis mostram as médias de semivariância em intervalos regulares, e a linha azul ajustada pelo modelo Hole Effect sugere um bom ajuste. A figura também apresenta o erro padrão da krigagem, evidenciando uma concentração de menores erros no centro da área e maiores na borda da área de estudo.

A figura 16 apresenta o gráfico de dispersão entre valores medidos e previstos, com uma linha de regressão linear. A dispersão dos pontos ao redor da linha de referência indica a variação nos erros de previsão. A técnica de krigagem permitiu a estimativa de matéria orgânica em locais sem medições diretas, com maior precisão no centro e maior incerteza nas bordas.

Figura 16 - Gráfico de dispersão dos dados mensurados e preditos, extraído de uma etapa da krigagem no Qgis.



Fonte: Autora 2024

O modelo de melhor desempenho foi o linear com patamar, apresentando o RMSE de 7,22, confirmando sua eficácia na espacialização dos dados de matéria orgânica. Os resultados da geoestatística revelam que existe um padrão espacial concêntrico da distribuição da Matéria Orgânica no Solo da área de estudo.

### 3.2. Distribuição e espacialização índices espectrais: dados Sentinel-2A


O estudo da distribuição de MOS na área de estudo também foi realizado com o uso de dados espectrais do satélite Sentinel-2A. A tabela 6 e figura 17 apresentam uma exploração da distribuição desses dados espectrais no interior da área úmida.

Tabela 6 – Mineração dos dados dos *pixels* de cada banda de 10 m do satélite Sentinel-2A na região da área úmida.

Sentinel-2A				
	B2	B3	B4	B8
	496.6nm	560nm	664.5nm	835.1nm
<b>Min</b>	0.02830	0.04640	0.05110	0.1584
<b>1st Qu</b>	0.03410	0.05335	0.06725	0.1810
<b>Median</b>	0.03640	0.05730	0.07200	0.1946
<b>Mean</b>	0.03659	0.05761	0.07258	0.2018
<b>3rd Qu</b>	0.03865	0.06180	0.07710	0.2152
<b>Max</b>	0.04630	0.07270	0.09580	0.3230

Fonte: Autora, 2023.

Figura 17 – Boxplot dos *pixels* de cada banda de 10 m do satélite Sentinel-2A dentro da área úmida.



Fonte: Autora, 2023.

A leitura da figura 17 e tabela 6 permite entender que a banda NIR captura a maior variância de dados dos alvos no interior da área úmida, que é a reflexão da diversidade e heterogeneidade de alvos. Desse modo, essa etapa de distribuição dos dados permite entender que os índices espectrais que envolvem a banda NIR do Satélite Sentinel-2A possuem, em tese, uma melhor capacidade de discernimento dos dados no interior da AU.

### 3.2.1 Índices espectrais derivados de dados Sentinel-2A

As variáveis utilizadas no modelo de predição de MOS foram índices calculados com as bandas do satélite Sentinel-2A, envolvendo índices espectrais. O índice denominado *Normalized Difference Vegetation Index* (NDVI) é calculado com as bandas (B8) NIR em 835.1 nm e a (B4) Red em 664.5 nm. O *Global Vegetation Moisture Index* (GVMI) é calculado através das bandas NIR (B8) em 835.1 nm e SWIR 1 (B11) em 1613.7 nm. O índice *Moisture Stress Index* (MSI) utiliza a banda SWIR 1 (B11) em 1613.7 nm e a banda NIR (B8) em 835.1 nm.

O *Optimized Soil Adjusted Vegetation* (OSAVI) é calculado utilizando os canais NIR (B8) em 835.1 nm e o canal RED (B8) em 664.5 nm e utiliza a constante L como um fator de correção do solo sendo o valor dessa constante definido como 0,16. O *Soil-Adjusted Vegetation Index* (SAVI) é calculado através das bandas (B8) NIR em 835.1 nm e a (B4) Red em 664.5 nm, o índice ajusta através da constante L que tem o valor de 0,5 dessa forma compensando as regiões onde existe maior influência do solo. O índice *Visual Atmospheric Resistance Index* (VARI) utiliza as bandas (B3) Green em 560 nm, a banda (B4) Red em 664.5 nm e a banda (B2) blue em 496.6 nm. O índice *Excess Green Index* (EXG) utiliza as bandas GREEN (B3) em 560 nm, RED (B4) em 664.5 nm e BLUE (B2) em 496.6 nm.

O *Soil Brightness Index* (SBIMSS) é calculado com Green (B3) em 560 nm, Red (B4) em 664.5 nm, RedEdge 2 (B6) em 740.2 nm, Water vapor (B9) em 945 nm. O *Soil Composition Index* (SOIL) é calculado com as bandas SWIR 1 (B11) em 1613.7 nm e Red (B4) em 664.5 nm. O *Clay index* (CLAY) é calculado com as bandas SWIR 1 (B11) em 1613.7 nm e SWIR 2 (B12) em 2202.4 nm. O *Ferrous Index* (FERROUS) é calculado com as bandas SWIR 1 (B11) em 1613.7 nm e SWIR 2 (B12) em 2202.4 nm. O *Ferric Iron Index* (FE) é calculado com as bandas NIR (B8) em 835.1 nm, SWIR 2 (B12) em 2202.4 nm, Green (B3) em 560 nm e Red (B4) em 664.5 nm. O *Ferric Iron Index* (FE iron) é calculado com a Red (B4) em 664.5 nm e Green (B3) em 560 nm.

Tabela 7 – Mineração dos dados dos índices do satélite Sentinel-2A.

ID	MIN	MAX	RANGE	MEAN	STD	SUM
<b>CLAY</b>	1,17	1,24	0,0714	1,22	0,014	350,21
<b>EXG</b>	-0,096	0,008	0,104	-0,040	0,010	-11,57
<b>FE</b>	1,68	1,81	0,122	1,75	0,022	501,25
<b>FEIRON</b>	0,956	1,03	0,075	0,980	0,011	280,51
<b>FERROUS</b>	0,806	0,852	0,045	0,82	0,009	235,03
<b>GVM</b>	0,120	0,182	0,062	0,148	0,011	42,48
<b>MSI</b>	0,806	0,954	0,148	0,893	0,029	255,6
<b>NDVI</b>	0,050	0,134	0,083	0,083	0,011	23,99
<b>OSAVI</b>	0,040	0,119	0,783	0,070	0,011	20,25
<b>SAVI</b>	0,028	0,100	0,071	0,054	0,010	15,71
<b>SBIMSS</b>	1,31	1,38	0,074	1,34	0,015	384,46
<b>SBL</b>	-0,660	-0,507	0,153	-0,605	0,021	173,15
<b>SOIL</b>	-0,014	0,031	0,045	0,013	0,008	3,73
<b>VARI</b>	0,002	0,083	0,081	0,058	0,012	16,66

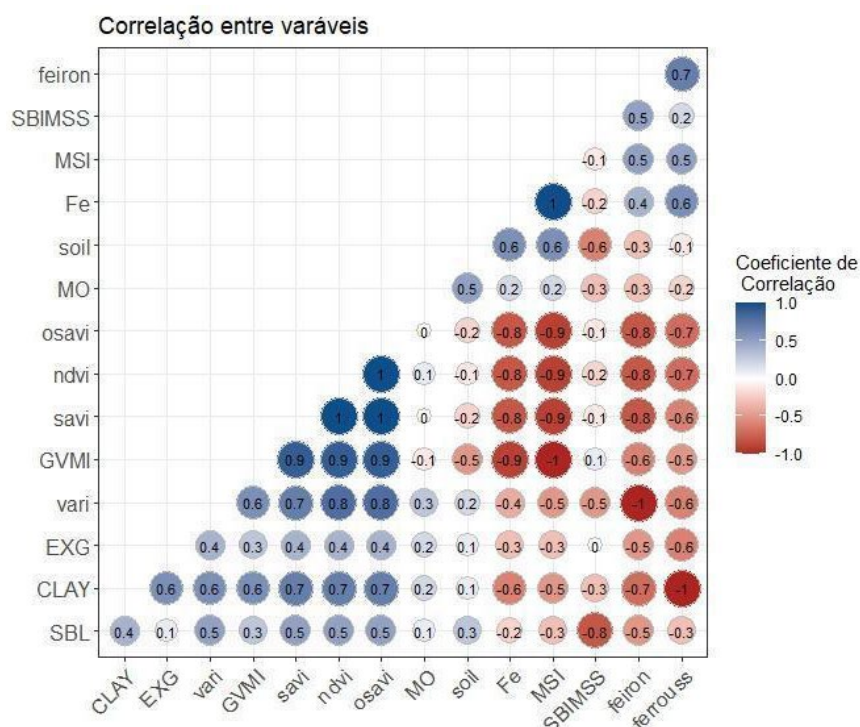
Fonte: Autora, 2024.

Os índices que tiveram maior desvio padrão foram MSI, FE e SBL. Os índices que apresentaram maior intervalo foram OSAVI, SBL e MSI.

### 3.2.2 Correlação índices espectrais Sentinel-2A e MOS

Em uma abordagem exploratória para examinar as relações entre os índices espectrais Sentinel-2A com os dados MOS obtidos em trabalho de campo foi realizado a correlação de Pearson que resultou em uma matriz que permite a visualização das distribuições de correlações.

Figura 18 - Matriz de correlação entre as variáveis do Sentinel-2A e a MOS.



Fonte: Autora, 2024.


A variável MOS apresentou correlações positivas fracas com os índices VARI, EXG, CLAY, SBL, Fe e NDVI. A MOS apresentou uma correlação positiva moderada com o índice SOIL e o  $R^2$  entre eles foi de 0,5. A variável MOS apresentou correlações negativas fracas com GVMl, SBIMSS, Feiron e Ferrous.

### 3.2.3 Análise de componentes principais dados espectrais Sentinel-2A e MOS

O resultado da análise de componentes principais revelou quais dentre os índices espectrais (variáveis dependentes) possuem maior capacidade explicativa para o modelo de previsão e quais são os mais correlacionados com a variável suplementar quantitativa MOS (variável dependente).

Na Figura 19 podemos observar a magnitude das duas primeiras dimensões, que explicam 81,44% do fenômeno; o estudo não identificou *outliers*. A dimensão 1 exprime 61,52% e apresentou um subconjunto com as 7 variáveis que mais explicam o fenômeno. A dimensão 2 exprime 19,91% e apresentou 8 variáveis que contêm maior potencial para explicar o fenômeno.


Figura 19 - Gráfico de variâncias acumuladas das dimensões de Análise de Componentes Principais (ACP) entre as variáveis do Sentinel-2A e a MOS.



Fonte: Autora, 2024.

O Círculo de Correlação da Análise de Componentes, na Figura 20, apresenta a distribuição dos valores de magnitude de cada índice no modelo de análise de componentes principais. Os agrupamentos sugerem os padrões de variância em relação ao fenômeno que se quer compreender.

Figura 20 – Círculo de Correlação da Análise de Componentes Principais entre as variáveis do Sentinel-2A e a MOS.



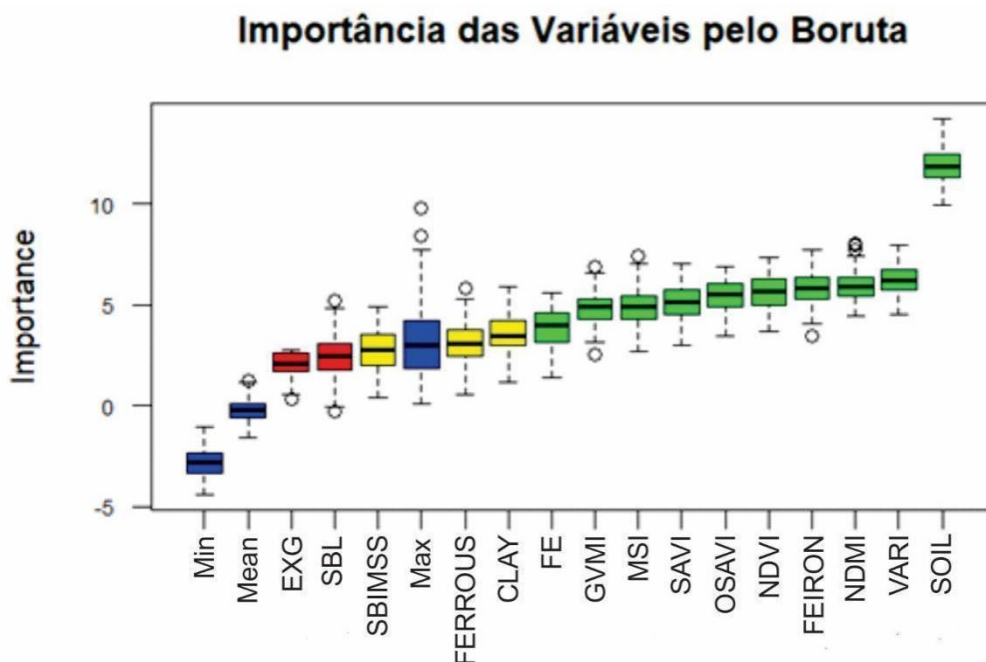
Fonte: Autora, 2023.

O resultado da análise de componentes principais evidenciou os principais índices correlacionados com a Matéria Orgânica no Solo na sequência de importância: NDMI (0,96), NDVI (0,96), OSAVI (0,96) e SAVI (0,95).

### 3.2.4 Seleção de variáveis Boruta: dados Sentinel-2A

O resultado da seleção de variáveis pelo método boruta, abordagem realizada entre índices espectrais Sentinel-2A e dado MOS, estabelece as variáveis com maior importância explicativa da variável dependente MOS (Figura 21).

Figura 21 – Importância das variáveis pelo Boruta do valor mediana de cada índice do Sentinel-2A.




Fonte: Autora, 2024

O primeiro *boxplot* verde na região direita do gráfico acima representa o índice SOIL com o valor de (1038), sendo a variável que apresentou melhor desempenho na primeira interação entre as variáveis e o Random Forest. Os próximos índices seguem uma ordem de importância global das covariáveis e estão hierarquicamente organizados, do de maior para o de menor relevância. Como resultado do primeiro modelo de Random Forest, obteve-se a seguinte sequência de relevância: SBIMSS (647,7), VARI (511,9), FEIRON (507,4), MSI (476), FE (461,9), GVMl (450,4), NDVI (405,7), NDMI (405,6), OSAVI (395,6), SAVI (378,2), CLAY (364,2), FERROUS (361).

A segunda rodada do Boruta resultou na seleção de variáveis mais relevantes a partir do resultado da primeira rodada (Figura 22).

Figura 22 – Importância das Top Variáveis da Mediana de cada índice dos dados do Sentinel-2A.




Fonte: Autora, 2024.

As variáveis selecionadas como mais importantes para explicar o fenômeno foram FEIRON, FE, MSI, SBIMSS, SOIL e VARI. O desempenho do modelo foi calculado através da relação entre as medianas das variáveis que foi de  $R^2$ : 0,8987175, o erro médio quadrado que foi de RMSE: 3,219845, e o erro médio absoluto que foi de MAE: 2,500167.

A espacialização dos índices que foram selecionados como os mais relevantes tem significativa importância para explicar o resultado espacial do modelo de predição de MOS na região da área úmida (Figura 23). Os índices FEiron, MSI, VARI e SOIL delimitaram muito bem as bordas da área úmida e evidenciaram os diferentes usos do solo em cada lado da área úmida. A região central da área úmida apresenta uma variação que foi destacada nos mapas dos índices FE, MSI e SBIMSS.

Figura 23 – Mapas Top Variáveis, dos índices calculados com o Sentinel-2A.



Fonte: Autora, 2024

### 3.3 Distribuição e espacialização dos índices espectrais e MOS: dados RPAS

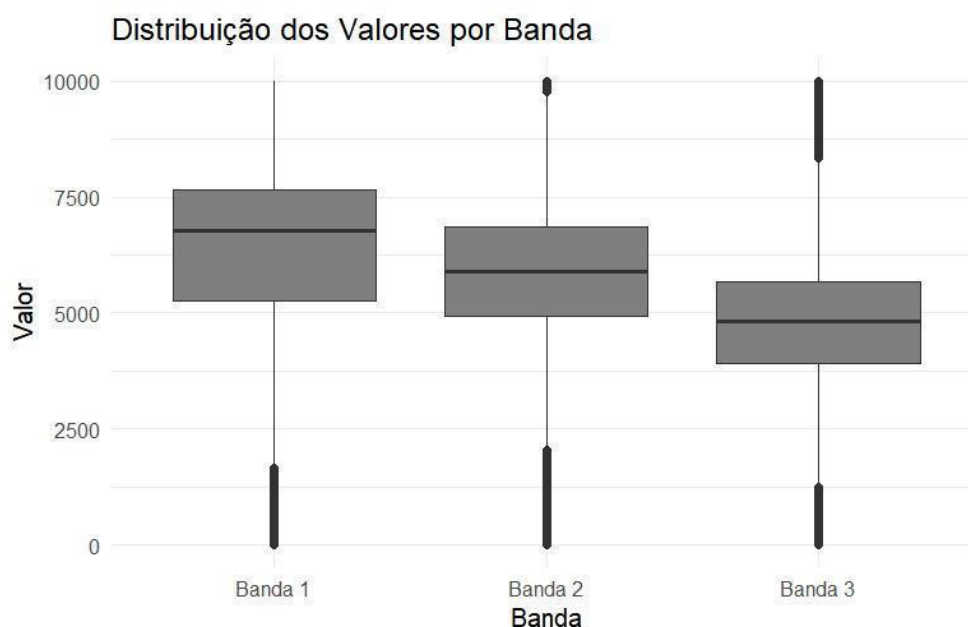
Os resultados da distribuição e espacialização da MOS por meio dos índices espectrais com dados RPAS foram realizados por meio de identificação e modelagem dos índices com maior relevância no banco de dados. A primeira abordagem neste contexto é apresentada na tabela 8 e figura 24, apresentam a distribuição dos dados espectrais do sensor RGB RPAS no interior da área úmida.

Tabela 8 – Mineração dos dados dos pixels de cada banda RGB do RPAS  
(Dados Normalizados).

RPAS	R (B1)	G (B2)	B(B3)
Min	0	0	0
Q1	5254,902	4941,176	3921,569
Median	6784,314	5882,353	4823,529
Mean	6296,886	5784,602	4736,002
Q3	7647,059	6862,745	5686,274
Max	10000	10000	10000

Fonte: Autora, 2024.

Figura 24 – Boxplot dos pixels de cada banda do RPAS.



Fonte: Autora, 2024.

A análise da Figura 25 e da Tabela 7 possibilitam a compreensão de que a banda red, representada pela B1, tem maior variabilidade, seguida pela banda verde (B2) e a banda azul (B3). Essa variabilidade pode indicar que o alvo compreende fatores que condicionam a resposta da reflectância nas faixas vermelha e verde. Os fatores que condicionam a resposta da reflectância nas faixas vermelha e verde estão relacionados às características da superfície, que englobam propriedades da vegetação como cobertura do dossel e clorofila, e propriedades do solo como cor e umidade. A maior variabilidade da banda vermelha também indica que os índices espectrais RGB derivados da banda

vermelha, possuem a tendência de maior captura das diferenças espectrais na área de estudo.

### 3.3.1 Índices espectrais derivados de dados RPAS

A análise dos resultados dos índices espectrais do satélite RPAS, devido a utilização de apenas bandas RGB, a maioria dos índices estão relacionados com as características da distribuição da vegetação. Deste modo, todos os índices abaixo são variações dos índices clássicos, porém utilizando apenas as bandas RED (634-666 nm), BLUE (434 - 466 nm) e GREEN (544 - 576 nm). Os valores obtidos revelam a distribuição de valores e de posição de cada variável na área de estudo.

O *Normalized Green-Red difference index* (NGBDI) é calculado com as bandas GREEN (544-576 nm) e BLUE (434-466 nm). O *Modified Green Red Vegetation Index* (MGVRI) utiliza as bandas GREEN (544-576 nm) e RED (634 - 666 nm). O *Red-Green Reflectance Ratio* (RGBVI) é calculado com as bandas GREEN (544-576 nm), BLUE (434 - 466 nm) e RED (634-666 nm). O *Photochemical Reflectance Index* (MPRI) que utiliza as bandas GREEN (544-576 nm) e RED (634-666 nm). O *Green Leaf Index* (GLI) utiliza as bandas GREEN (544-576 nm), RED (634-666 nm) e BLUE (434 - 466 nm).

O *Excess green* (EXG) é calculado com as bandas GREEN (544-576 nm), RED (634-666 nm) e BLUE (434 - 466 nm). O *Excess-red index* (EXR) que utiliza as bandas RED (634-666 nm) e GREEN (544-576 nm). O *Excess green-excess red* (EXGR) é calculado entre os índices EXG – EXR. O *Color index of vegetation extraction* (CIVE) é calculado com as bandas RED (634-666 nm), BLUE (434 - 466 nm) e GREEN (544-576 nm). O *Vegetativen* (VEG) utiliza as bandas GREEN (544-576 nm), RED (634-666 nm) e BLUE (434 - 466 nm).

O *Visible Atmospherically Resistant Index* (VARI) utiliza as bandas RED (634-666 nm) e BLUE (434 - 466 nm). O *Triangular Greenness Index* (TGI) utiliza as bandas GREEN (544-576 nm), RED (634-666 nm) e BLUE (434 - 466 nm). O *Coloration Index* (CI) é calculado com as bandas RED (634-666 nm) e BLUE (434 - 466 nm). O *Red-Green-Blue Vegetation Index* (RGVBI) é calculado com as bandas GREEN (544-576 nm), BLUE (434 - 466 nm) e RED (634-666 nm). O *Normalized Difference Index* (NDI) é calculado com as bandas GREEN (544-576 nm) e RED (634-666 nm). O *Daylight Adapted Vegetation Index* (DAVI) é calculado com as bandas GREEN (544-576 nm),

RED (634-666 nm) e BLUE (434 - 466 nm). O *Ratio Simples* (RG) é calculado com as bandas RED (634-666 nm) e GREEN (544-576 nm).

Tabela 9 – Mineração dos dados dos índices do RPAS.

ID	MIN	MAX	RANGE	MEAN	STD	SUM
<b>CIVE</b>	-79	42	122	-10,38	12	-194
<b>CRI1</b>	-108	145	254	36	24	688
<b>CRI2</b>	-1	1	2	0,124	0,139	233
<b>DAVI</b>	0	47	47	1,22	0,265	229
<b>EXG</b>	-60	210	270	52,79	27	987
<b>EXGR</b>	-185	279	465	15	46	299
<b>EXR</b>	-108	145	254	36	24	688
<b>GLI</b>	-1	1	2	0,108	0,070	2026
<b>MGVRI</b>	-1	1	2	0,124	0,139	233
<b>MPRI</b>	-1	1	2	0,064	0,775	120
<b>NGBDI</b>	-1	1	2	0,158	0,080	296
<b>NDI</b>	-46,5	214,5	261	56,23	22,85	105
<b>RG</b>	0	27	27	0,887	0,124	166
<b>RGBVI</b>	-1	1	2	0,216	0,127	405
<b>TGI</b>	-27,80	108	136	28,83	13,91	539
<b>RGVBI</b>	-1	1	2	-0,3867	0,0655	-723
<b>VADI</b>	-56	126	182	15,30	15,25	2863
<b>VEG</b>	0	254	254	122	39,02	2286
<b>CI</b>	-94	133	227	22,18	12,77	415


Fonte: Autora, 2024.

Os índices que apresentaram maior variância foram: EXGR, EXG e NDI. Os índices que apresentaram maior desvio padrão foram: EXGR, VEG e EXG.

### 3.3.2 Correlação índices espectrais RPAS e MOS

Em uma primeira tentativa de relacionar os índices espectrais RPAS com os dados de MOS obtidos no trabalho de campo, foi realizada a correlação de Pearson que resultou em uma matriz que permite a visualização das distribuições dos valores das variáveis dependentes e independentes.

Figura 25 – Matriz de Correlação entre as variáveis do RPAS e a MO.



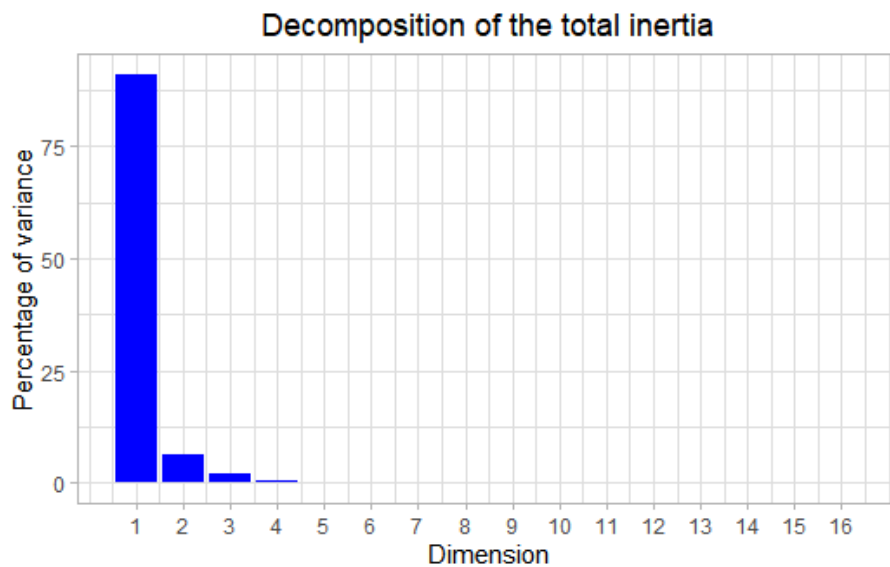
Fonte: Autor, 2024.

Verifica-se que houve baixa correlação com o teor de matéria orgânica do solo (MO, na Figura 25). Os índices DAVI, RGBVI, CIVE e EXR tiveram uma correlação negativa baixa com a variável MO. Os índices EXGR, EXG, TGI e CI tiveram uma correlação positiva baixa com a variável MO.

### 3.3.3 Análise de componentes principais dados espectrais RPAS e MOS

O resultado da ACP apontou para a redução dos dados em duas dimensões com 97,1% da variabilidade total do conjunto de dados. Sendo a primeira componente com 87,39% e a segunda componente com 6,11%. No gráfico pode se observar a inexpressividade da dimensão dois, que expressou 6,11% da variabilidade dos dados. Os dados identificados são os que mais contribuíram para a consolidação do eixo. Esse resultado revela que os dados RPAS conseguem obter um alto poder de manutenção da variabilidade em poucas dimensões.


Figura 26 – Gráfico de variâncias acumuladas das dimensões de Análise de Componentes Principais (PCA).



Fonte: Autora, 2024.

O Círculo de Correlação da Análise de Componentes, na Figura 27, apresenta a distribuição dos valores de magnitude de cada índice no modelo de análise de componentes principais. Os agrupamentos sugerem os padrões de variância em relação ao fenômeno que se quer compreender.

Figura 27 – Círculo de Correlação da Análise de Componentes Principais.



Fonte: Autora, 2024.

O resultado da análise de componentes principais evidenciou os principais índices correlacionados com a Matéria Orgânica no Solo na sequência de importância: CIVE


(0,94), DAVI (0,97), EXG (0,94), EXGR (0,97), EXR (0,94), GLI (0,99), MGVRI (0,99), MPRI (0,98), NDI (0,98) e RG (0,99).

### 3.3.4 Seleção de variáveis espectrais pelo Boruta: dados RPAS

A seleção de variáveis espectrais RPAS pelo algoritmo boruta, resultou na seleção de melhores variáveis espectrais (independentes) que melhor representam os dados de MOS (dependentes) em duas fases. Na primeira rodada de seleção (Figura 28) entre as médias de todos os índices do RPAS, o índice que mais apresentou correspondência foi RGBVI (1806,6) e em seguida o EXR (1089,8). A ordem de relevância definida pelo código foi: RGBVI (1806,6), EXR (1089,8), CI (893,2), NGBDI (666,4), EXGR (326,4), GLI (262,7), DAVI (231,7), VARI (222,3), RG (206,1), NDI (163,3), MPRI (150,0) e MGVRI (136,7).

A presença expressiva de mais *outliers* nos dados do satélite, o que afeta consideravelmente o Random Forest. As variáveis do RPAS também foram analisadas a partir dos resultados dos índices que apresentam maior variância, como podemos ver nos *boxplots*, abaixo (Figura 30).

Figura 28 - Importância das variáveis pelo Boruta do valor da média de cada índice calculado com dados do RPAS.




Fonte: Autora, 2024

Na segunda rodada de seleção, ordenou-se os índices do RPAS mais relevantes entre as variáveis mais importantes. As variáveis que apresentaram maior importância foram: CI, EXGR, EXR, NGBDI, RGBVI e RGVBI. O desempenho do modelo foi

calculado através da relação entre as médias das variáveis que foi  $R^2: 0,88$ ,  $RMSE:3,62$ ,  $MAE: 2,85$  e o  $MSE: 13,11$ .


Figura 29 - Importância Top Variáveis da Média de cada índice dos dados de RPAS.



Fonte: Autora, 2024

A partir das seleções de variáveis mais relevantes, foi possível realizar a espacialização dos índices de maior relevância para verificar a distribuição espacial de cada variável para realizar as fases posteriores de modelagem dos índices selecionados, em conjunto com os dados MOS.

Figura 30 – Mapas Top Variáveis, dos índices calculados com o RPAS.



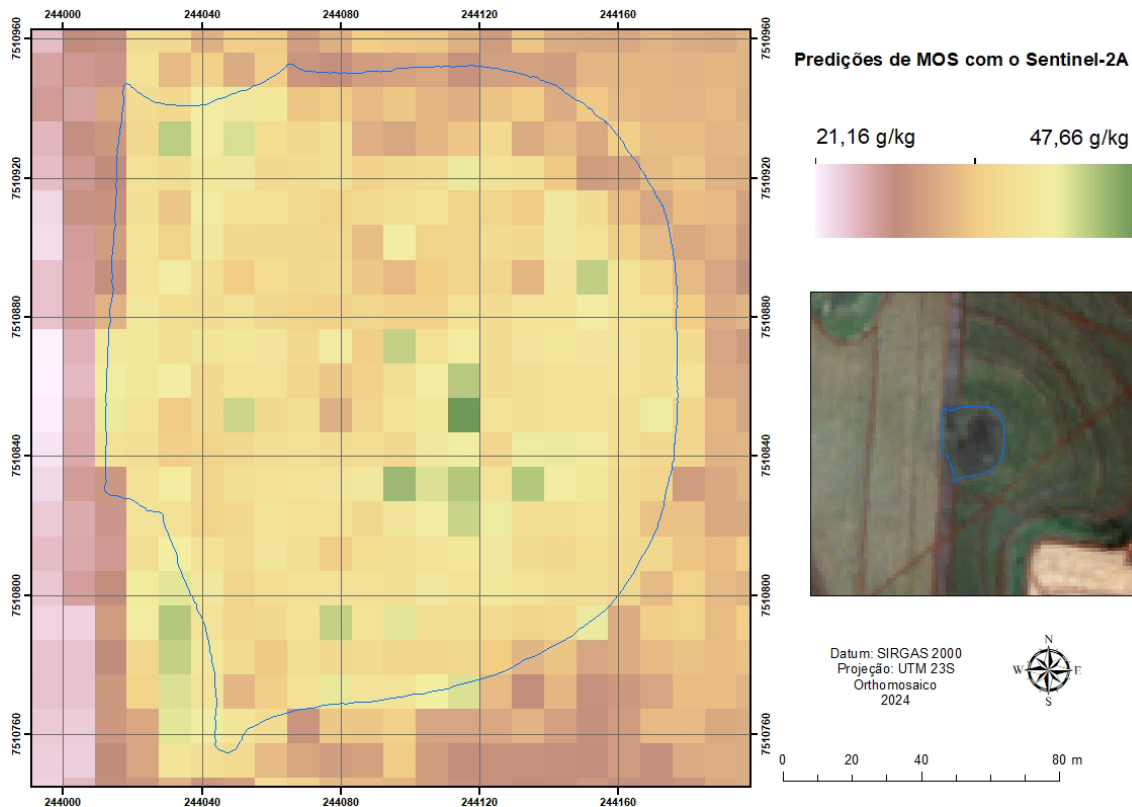
Fonte: Autora, 2024

#### 4. Predição de MOS com o satélite Sentinel-2A

O mapa da Figura 31 apresenta a distribuição da matéria orgânica no solo realizado a partir dos valores de mediana dos índices espectrais Sentinel-2A. Especificamente, os índices com maior destaque foram: FEIRON, FE, MSI, SBIMSS, SOIL e VARI. A análise visual do mapa da figura 31 revela que a faixa de menor valor caracterizado pelas cores brancas, marrom e vermelha, tem a tendência de serem concentradas nas bordas e área externa de áreas úmidas. Por outro lado, as cores amarelas e verde possuem uma tendência de se concentrarem de forma centralizada.

A análise da distribuição espacial do carbono, com base nos dados espectrais do Sentinel-2A, indica uma tendência de aumento nos valores de carbono da borda em direção ao interior da área úmida. Contudo, apesar dessa tendência centralizada, observa-se a presença de pontos isolados, representados pelas tonalidades marrons e verdes, distribuídos dentro da área estudada.

Figura 31 - Predição de MOS com o sensor MSI do sensor orbital Sentinel-2A.



Fonte: Autora, 2024

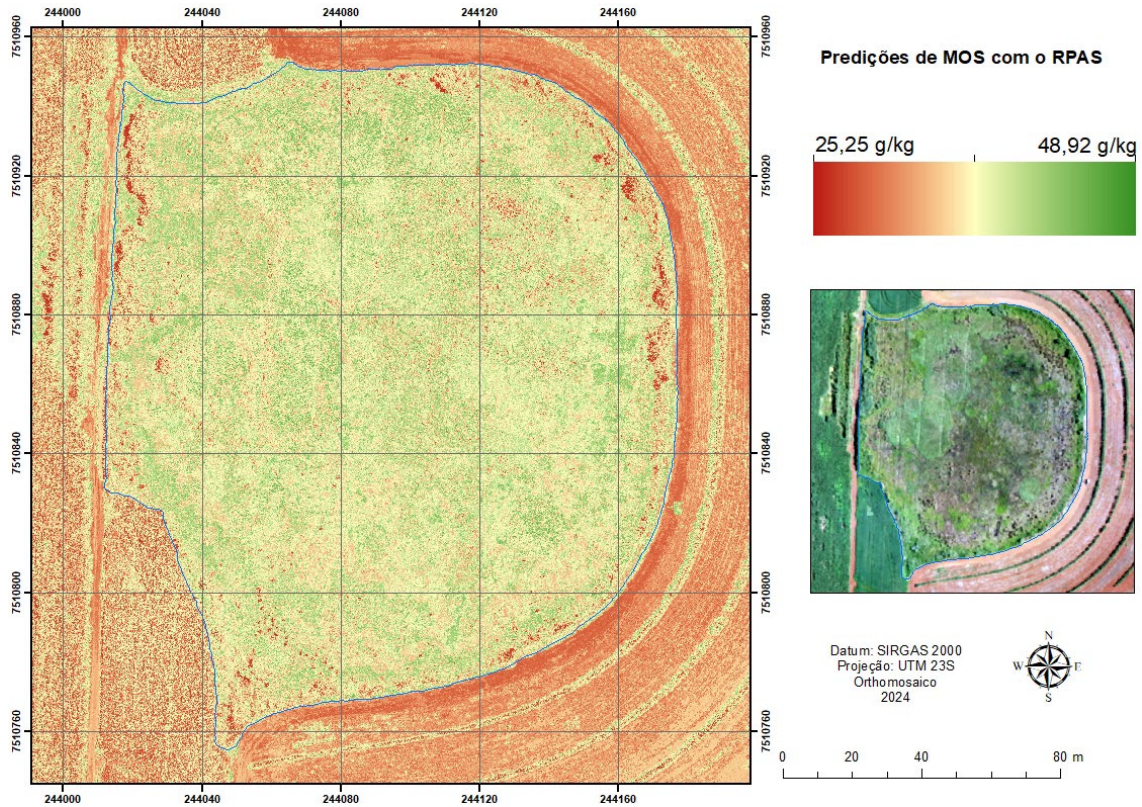
Segundo o modelo, o valor mínimo de MOS foi de 22,16 g/kg e o máximo foi de 47,66 g/kg. Esse intervalo está de acordo com os dados coletados, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg. A acurácia do modelo resultou em uma correlação positiva com o  $R^2$ : 0,88, o erro quadrado foi de RMSE: 3,62 e o erro médio absoluto MAE: 2,64. Os valores de acurácia com o RMSE: 3,62 e o MAE: 2,64, revelam um alto poder de modelagem do sensor Sentinel-2A.

#### 4.1. Predição de MOS por meio de índices espectrais: dados RPAS

O mapa da figura 32 apresenta a distribuição da matéria orgânica no solo realizado a partir dos valores de mediana dos índices espectrais RPAS: CI, EXGR, EXR, NGBDI, RGBVI e RGVBI. Com a seleção das variáveis espectrais mais relevantes, foi realizada

a modelagem espacial para predição de matéria orgânica no solo na pequena área úmida a partir de técnicas estatísticas utilizando as bandas RGB do Phantom 4 PRO.

Figura 32 - Predição de MOS com a imagem de RPAS sem as margens laterais da área úmida.



Fonte: Autora, 2024

O padrão visual no mapa 34 evidencia os valores mais baixos do lado de fora da área úmida e os valores mais altos no interior da área úmida. A modelagem do carbono dos dados RPAS retornou com um valor mínimo de 25,25 g/kg e o valor máximo de 48,92 g/kg de MOS. Esse intervalo está próximo dos dados coletados, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg. A acurácia do modelo resultou em uma correlação positiva com o  $R^2$ : 0,88. O erro quadrado foi de RMSE: 3,62 e o erro médio absoluto de MAE: 2,85 e o erro quadrático médio foi de MSE: 13,11.

#### 4.2. Comparação dos modelos de predição dados Krigagem x RPAS x Sentinel-2A

Ainda que as diferenças de resolução entre a modelagem de MOS com os dados de krigagem, Sentinel-2A e RPAS existam, a análise visual da distribuição de MOS desses modelos revelaram que há uma tendência concêntrica.

Quanto aos dados de comparação de estatística descritiva das fontes de dados (Tabela 10), a krigagem teve como valor mínimo 26,91, a média foi de 35,58, e o valor máximo foi de 43,66. O modelo preditivo com as variáveis do RPAS teve como valor mínimo 32,36, enquanto a média foi de 36,02, a mediana de 36,37 e o valor máximo com 39,32. O modelo preditivo com as variáveis do Sentinel-2A obteve como valor mínimo 22,62, a média de 34,83, a mediana foi de 36,37 e o valor máximo com 43,88.

Tabela 10 - Estatística Descritiva dos Modelos de Predição

Estatística Descritiva	Sentinel-2A	RPAS	Krigagem
<b>Mínimo</b>	22,62	32,36	26,91
<b>1° Quartil (Q1)</b>	32,50	33,71	32,86
<b>Mediana</b>	36,13	36,37	35,45
<b>Média</b>	34,83	36,02	35,58
<b>3° Quartil (Q3)</b>	38,24	38,12	38,29
<b>Máximo</b>	43,88	39,32	43,66
<b>Amplitude</b>	21,26	6,96	16,75
<b>Variância</b>	49,93	6,83	31,03
<b>Desvio Padrão</b>	7,07	2,61	5,57

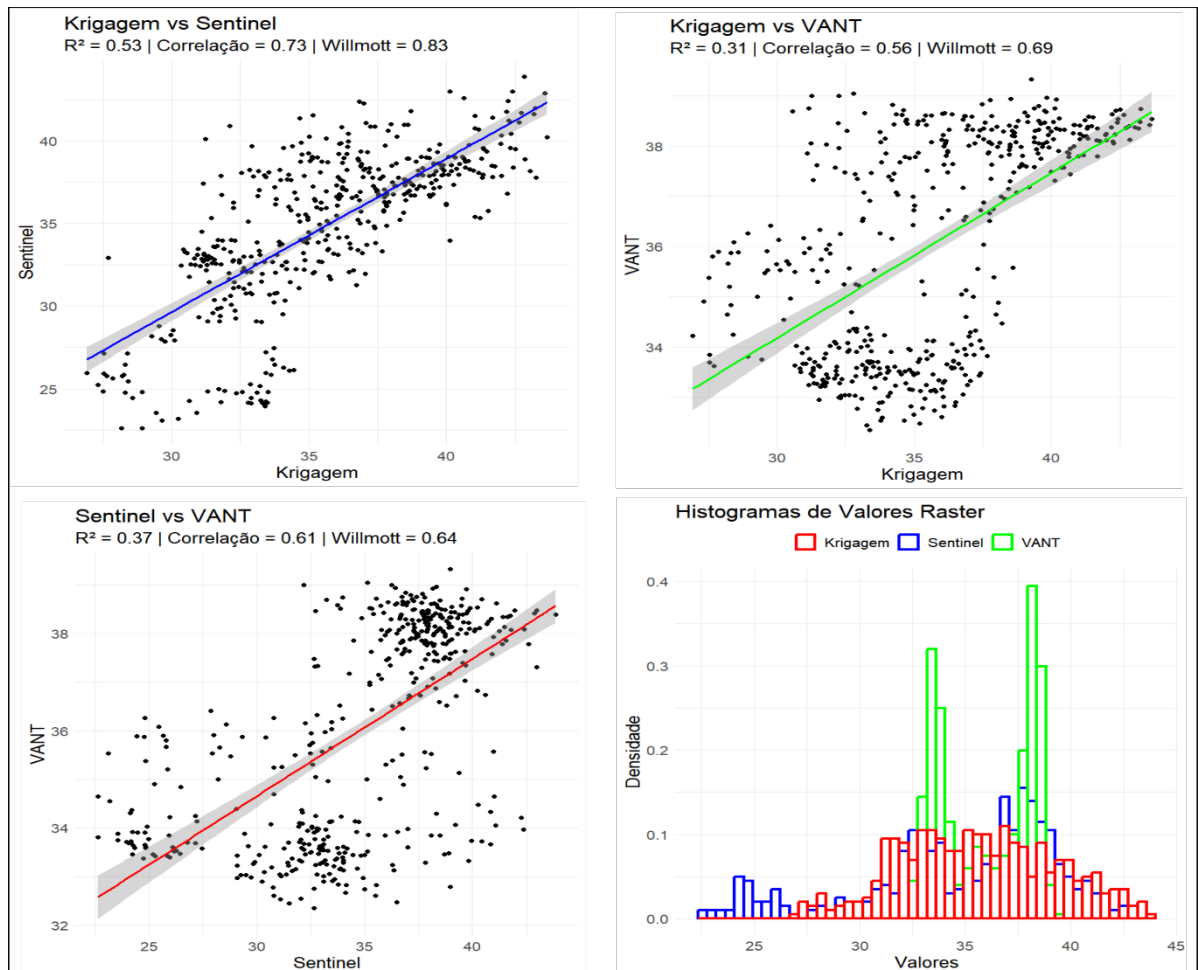
Fonte: Autora, 2014.

O modelo com maior amplitude foi o do Sentinel-2A, a maior variância também foi do modelo realizado com o satélite Sentinel-2A. O modelo que apresentou maior desvio padrão foi o modelo realizado com o satélite Sentinel-2A.

Os coeficientes de correlação determinação e similaridade entre os modelos de precisão de MOS (Tabela 10) apresentaram os seguintes resultados: entre a krigagem e o Sentinel-2A, a correlação espacial foi de 0,73, o coeficiente de determinação foi de 0,53 e o índice de concordância de Willmott (d) foi 0,83. O modelo preditivo do RPAS comparado com a Krigagem teve uma correlação espacial de 0,56, o coeficiente de determinação apresentou o valor de 0,31 e o índice de concordância de Willmott (d) teve o valor de 0,69. O modelo do Sentinel-2A comparado com o modelo do RPAS obteve como correlação espacial o valor de 0,61, o valor do coeficiente de determinação foi de 0,37 e o índice de concordância de Willmott (d) foi de 0,64.

A figura 33 ilustra a distribuição dos dados entre as variáveis Krigagem, Sentinel-2A e RPAS.

Figura 33 – Comparação de acurácia entre os a krigagem e os modelos preditivos do Sentinel-2A e do RPAS.



Fonte: Autora, 2024.

A distribuição do gráfico de dispersão revela uma menor faixa de erro entre as variáveis krigagem e Sentinel-2A, bem como uma menor distância dos pontos em relação a reta, além de uma correlação moderada com o  $R^2$  de 0,53. Por outro lado, a comparação da krigagem com o VANT apresentou maior erro e uma correlação fraca com o  $R^2$  de 0,31. Provavelmente, as diferenças observadas podem ser atribuídas aos índices utilizados no modelo do VANT, que diferem daqueles empregados no Sentinel-2A, uma vez que o sensor VANT não dispõe de uma banda específica para o infravermelho.

#### 4.3. Análise do uso da terra no entorno da área úmida

O município de Cordeirópolis é uma região que foi historicamente ocupada por atividades ligadas ao setor agropecuário. A região começou a ser ocupada no século XVIII, após a abertura dos caminhos que levavam ao Triângulo Mineiro, Goiás e Mato Grosso. Além dos negócios visando suprir as necessidades dos viajantes, estabeleceram-

se ao final do século XVIII e início do século XIX as primeiras grandes propriedades, destinadas ao plantio da cana de açúcar, que foi o principal produto cultivado até a década de 1840 (SANTOS, 2002). Ainda segundo esse autor, o cultivo da cana para produção de açúcar é superado pelo do café na década de 1850, mas as duas culturas dividem aqueles espaços até o início do século XX. Os núcleos urbanos se desenvolvem na região, que também passa por processo de industrialização nas primeiras décadas do século XX.

Conforme IBGE (1957), no município de Cordeirópolis a principal atividade econômica nos anos 1950 era o cultivo da cana de açúcar, seguido do arroz, do milho, do algodão e da fruticultura. A atividade pecuária era pouco desenvolvida e destinada sobretudo à produção de leite. A cobertura florestal do município ocupava 1.780 ha, sendo 380 ha de matas naturais e 1.400 ha de “matas formadas”. Nas últimas décadas do século XX, a cultura da cana ganha força novamente em virtude da demanda por energia.

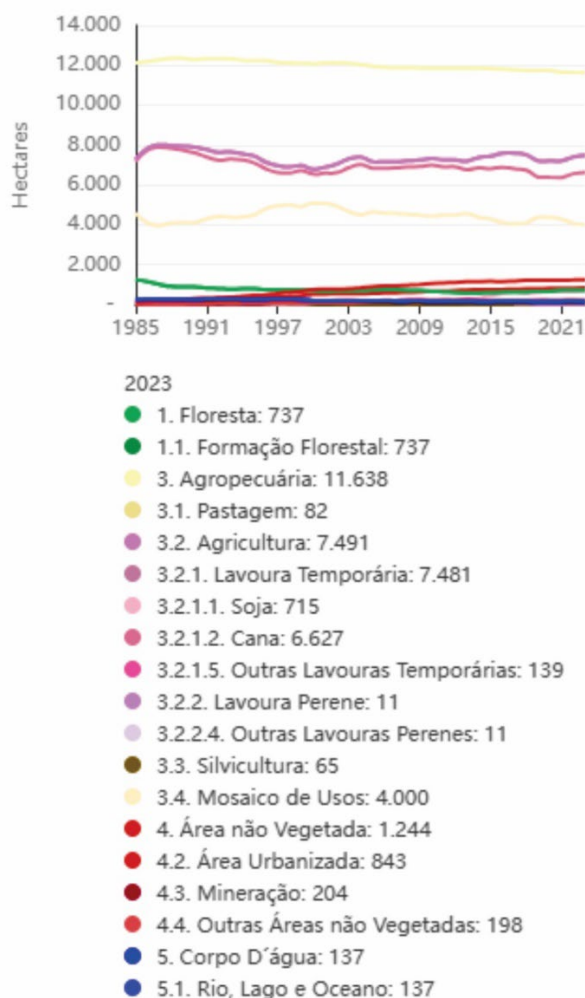
Segundo os dados estatísticos do MapBiomas, em 1985 o uso da terra do município já era dominado pela atividade agropecuária, com 12.125 ha, compondo 88,15%, e a área florestada tinha 1.238 ha, compondo 9% do território. Os dados para o ano de 2022 mudaram principalmente para outros tipos de classes, porque a importância e influência da agropecuária na região se manteve: a classe agropecuária ocupou 11.596 ha, compondo 84,30% do território, e as regiões florestadas ocuparam 724 ha, compondo 5,26% do território. A Figura 34 apresenta um gráfico com a dinâmica do uso da terra dos anos de 1985 a 2022.

A linha verde da Figura 14 representa a classe geral floresta, que é composta pelas classes: Formação florestal, formação savânica e floresta alagável. A linha bege escura representa formação natural não florestal que é composta pelas classes: Campo alagado, área pantanosa e formação campestre, afloramento rochoso e outras formações não florestais.

As linhas bege, rosa, vermelha e azul precisam de uma atenção especial, principalmente na região de Cordeirópolis. A linha bege representa a classe geral Agropecuária, que engloba as subclasses pastagem, agricultura, silvicultura e mosaico de usos. A subclasse agricultura tem uma cor rosa para se destacar devido à grande abrangência e relevância em território nacional. A linha vermelha representa a classe geral Área não vegetada, que engloba as subclasses, área urbanizada, mineração e outras áreas

não vegetadas. A linha azul representa a classe geral os corpos d'água que abrange as subclasses rio, lago e aquicultura.

Figura 34 – Estatísticas do uso da terra do município de Cordeirópolis para os anos de 1985 a 2023, segundo a plataforma MapBiomias.



Fonte: MapBiomias.

Na imagem Sentinel-2A (Figura 35), a mesma utilizada para o cálculo dos índices espectrais aqui apresentados, podemos observar os tipos de uso da terra ao redor da área de estudo. No período entre 1985 e 2023, o uso da terra no entorno da área úmida pesquisada foi sempre a cana de açúcar, enquanto o interior da área úmida foi classificado como “mosaico de usos” e pastagem, segundo o MapBiomias, o que revela o caráter regional do mapeamento que não consegue captar esses pequenos ecossistemas. Não há qualquer faixa de vegetação nativa protegendo o entorno da área úmida, tornando aquele ambiente muito vulnerável à influência externa. De fato, observou-se em campo que o

interior da área úmida foi altamente influenciado por pela atividade antrópica ao longo desses anos (Figura 38), pois, além do avanço da agricultura em suas bordas e de sua interseção na parte oeste por uma estrada (sob a rede de alta tensão), foram observados diversos tipos de espécies invasoras em seu interior.

Figura 35 – Mapa do município de Cordeirópolis e mapas do uso da terra (2000 a 2023).

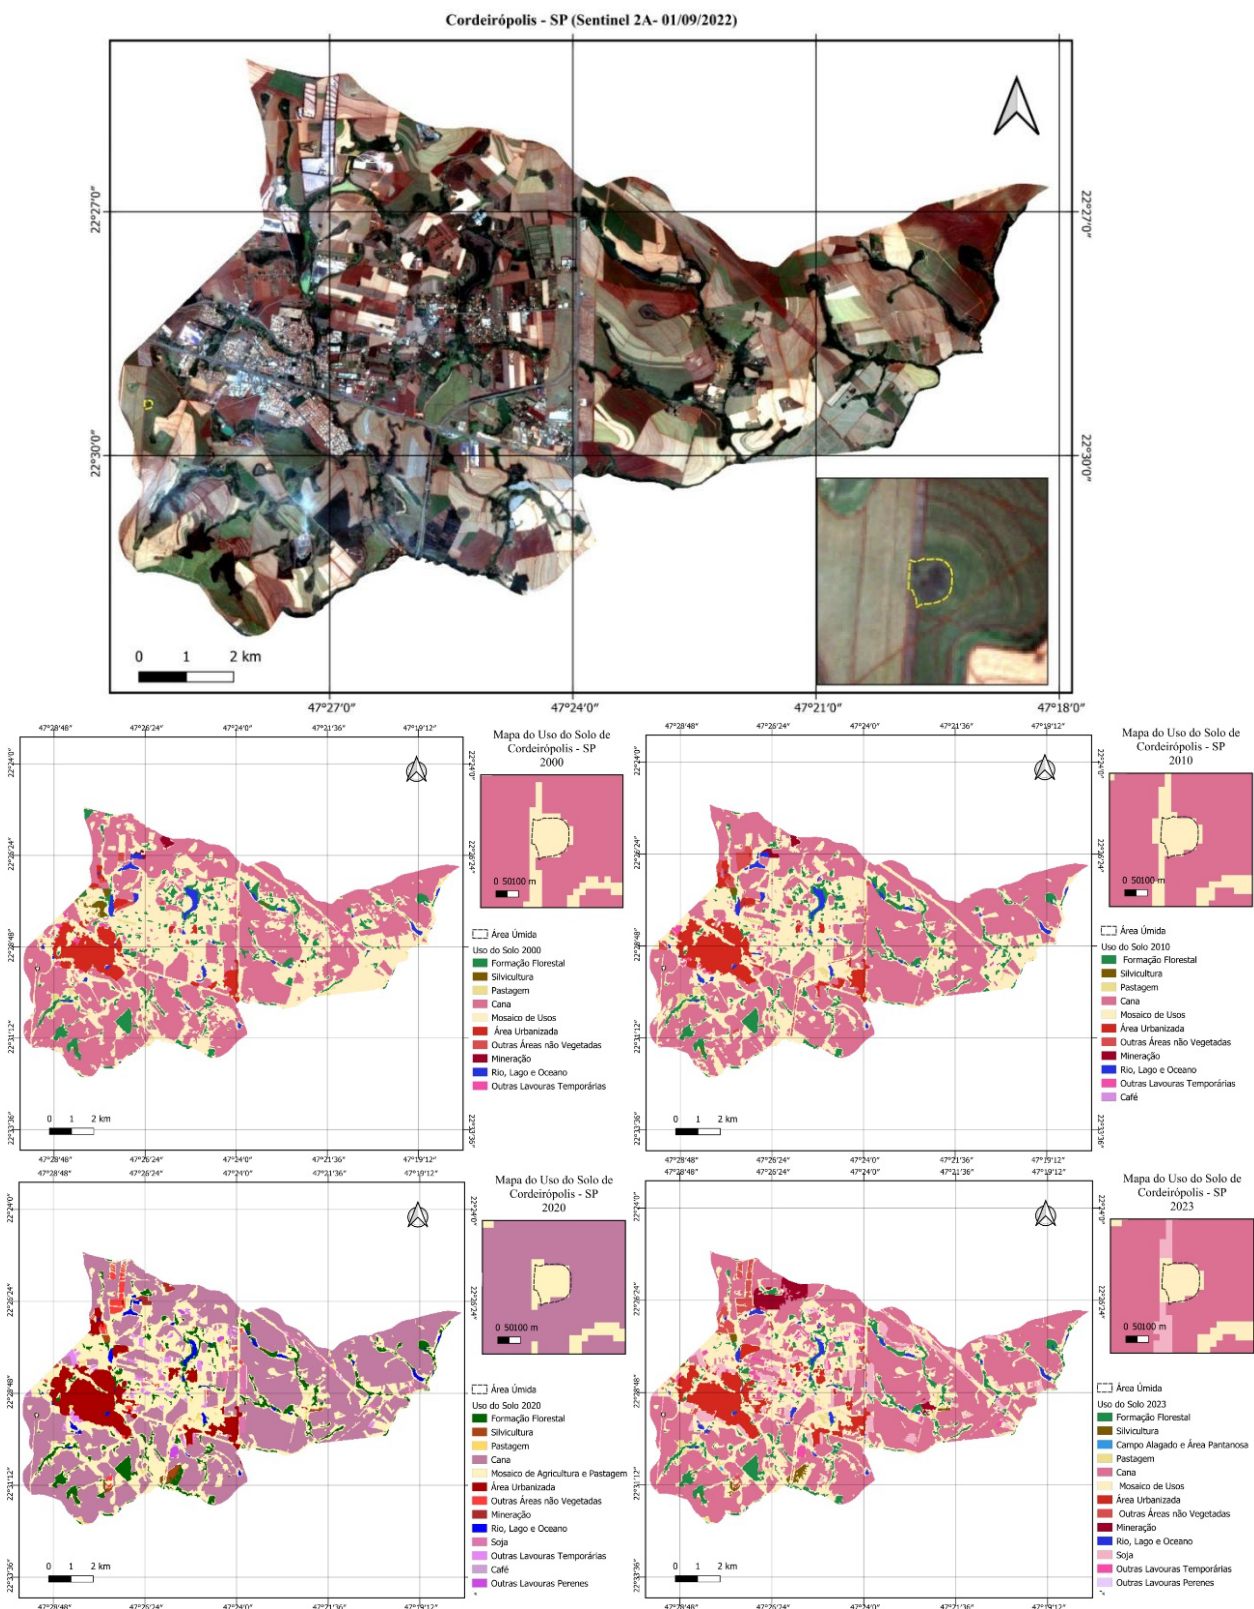



Figura 36 – Fotos da área de estudo e entorno, registradas em campo.



Fonte: Autora, 2024.

## 5. Discussão

### 5.1. Cálculo de MOS em pequenas áreas úmidas por krigagem

A krigagem é uma técnica geoestatística que espacializa dados pontuais, generalizando esses dados para uma escala local ou regional. Os trabalhos que utilizam a krigagem e a modelagem, especificamente de MOS ou COS, estão cada vez mais detalhados e com maior replicabilidade em diversas áreas, com diferentes características. O resultado da distribuição espacial da matéria orgânica no solo obtido por meio da krigagem ordinária universal, na presente pesquisa, realizada em uma área total de 25.823 m<sup>2</sup>, com 107 pontos amostrais.

Esse processo revelou que a distribuição possui um aproximadamente padrão concêntrico, com os valores aumentando de forma gradativa da borda para o centro da área mapeada. A partir da estatística descritiva do total das 107 amostras, foi possível verificar que o valor de teor mínimo de MOS foi de 20 g/kg e o valor máximo foi de 57 g/kg. O valor médio de MOS foi de 35,57 g/kg e o desvio padrão foi de 8,048 g/kg. Esta configuração reflete os gradientes de umidade, com tendência de maior acúmulo da matéria orgânica nas partes mais úmidas, geralmente aquelas do interior da área deprimida, devido a condições mais favoráveis para a preservação da MOS, como a menor oxigenação (Chapin III et al., 2002).

Maiores valores dentro da área úmida em comparação com a região externa já eram esperados. A área úmida está predominantemente coberta por gramíneas e a região central da área úmida é também a região mais deprimida. A borda da área úmida possui solos que foram revolvidos e que disponibilizaram nutrientes para contínuas safras, conforme o histórico do uso da terra, reduzindo a MOS disponível no horizonte superficial. As áreas úmidas isoladas são caracterizadas por uma heterogeneidade lateral do centro até a borda, que se manifesta nos diferentes valores médios dos *pixels*, por ser bordejada por rampas suaves com transições de componentes do solo. Os maiores teores em MOS se concentram na parte sul do interior da área úmida, indicando uma configuração assimétrica em relação ao centro da área úmida.

A técnica de krigagem permitiu estimar a matéria orgânica em locais onde medições diretas podem não estar disponíveis. A distribuição concêntrica pode refletir processos naturais relacionados ao regime hidrológico da área úmida, como deposição de material

orgânico, menor decomposição no centro devido a condições anóxicas, ou influência de vegetação específica que contribui mais significativamente para o acúmulo de matéria orgânica.

A krigagem da matéria orgânica do solo é a espacialização de uma variável química, e a distribuição dessa matéria é controlada por outras variáveis ambientais dinâmicas, fazendo com que a configuração da distribuição seja altamente complexa. O modelo que teve maior performance com os dados coletados de matéria orgânica foi o modelo Linear com patamar, com um RMSE de 7,22.

Chen et al., (2019) compararam a krigagem de COS com previsões utilizando índices vegetacionais e dados de reflectância, em um estudo em escala regional, no nordeste da China. Foi realizado em uma área de 3.592 km<sup>2</sup>, com mais de 300 pontos de amostragem, todas no horizonte superficial (0-20 cm). A krigagem produzida por Chen (2019) teve o R<sup>2</sup> de 0,32, o seu erro médio foi de -0,71 e o seu RMSE foi de 9,81. É relevante destacar que o modelo de previsão que teve melhor performance foi o de aprendizagem da máquina, que teve um R<sup>2</sup> de 0,60, erro médio de -0,38 e RMSE de 8,89.

Pouladi et al., (2019) realizou um trabalho sobre MOS na Dinamarca em uma área bastante pequena, de apenas 10 hectares, com no total 285 amostras. Em seus resultados ele alcançou, através da krigagem de MOS, o R<sup>2</sup> de 0,91 e o RMSE de 2,27. A modelagem realizada por Pouladi et al., (2019) comparou os resultados dos seguintes métodos: Cubist, Random Forest, Cubist-Kriging, Random Forest-kriging e Kriging. O trabalho concluiu que a melhor performance foi da própria krigagem. É relevante enfatizar que os resultados do RF foram R<sup>2</sup> de 0,89 e um RMSE de 4,20.

A variabilidade lateral dos teores de MOS depende de muitas variáveis, bióticas e abióticas (ver tópico 1.1.2 desta dissertação). Deste modo, essa variabilidade pode ser controlada por fatores não explicados no modelo e, para reduzir os valores de RMSE na previsão do teor de MOS em pequenas áreas úmidas, seria necessário considerar os fatores físicos estruturais que controlam a dinâmica dessas depressões fechadas e suas interações complexas como o clima e o relevo (Wang, 2019). Junta-se a isso o fato de que exploração do uso da terra há quase dois séculos na região circunvizinha à depressão acaba por acrescentando ruído no modelo. Portanto, podemos afirmar que o fenômeno de distribuição de MOS em depressões fechadas é estruturalmente complexo, reforçando que

esse fenômeno só pode ser explicado através de modelos não-estacionários (Kumar et al., 2012) e não-lineares (Wei Zhang, 2012).

Este fato demonstra que a variabilidade do conjunto de dados pode não ser satisfatoriamente capturada pelo modelo, possivelmente devido à complexidade intrínseca dos padrões espaciais da matéria orgânica do solo e pelo fato do intenso uso da terra ao redor da área de pesquisa. O resultado da modelagem de MOS e os parâmetros  $R^2$  e RMSE varia muito de área para área podendo ser um reflexo das complexidades hidrológicas, físicas, químicas, biológicas, todas inerentes a cada área úmida.

## **5.2. Predição do teor de MOS em pequenas áreas úmidas por satélites**

No presente trabalho, o modelo de predição de MOS a partir de variáveis calculadas através de bandas do satélite Sentinel-2A teve o valor mínimo de MOS de 22,16 g/kg e o máximo de 47,66 g/kg. Esse intervalo está de acordo com os dados de MOS coletados em campo e representados por meio da krigagem, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg. A acurácia do modelo resultou em uma correlação positiva, com o  $R^2$ : 0,88; o erro quadrado foi de RMSE: 3,44, e o erro médio absoluto MAE: 2,64.

Meiwei Zhang et al., (2021), sobre a planície norte de Songnen, no nordeste da China, com 281 amostras, produziu uma predição de MOS através das imagens do satélite Sentinel-2A e MODIS. Teve como resultados dos treinamentos da sua modelagem os valores  $R^2$  entre 0,56 e 0,67 e os RMSE entre 0,68% e 0,79%. Bouslihim et al., (2024) produziu uma modelagem para predição de MOS para uma área de 805 km<sup>2</sup> na região norte de Marrocos, utilizando 191 amostras, obtendo o coeficiente de determinação  $R^2$  de 0,90 e o RMSE de 0,37.

Neste trabalho, as variáveis mais importantes para o modelo de predição foram FEIRON, FE, MSI, SBIMSS, SOIL e VARI. No modelo de predição produzido por Meiwei Zhang et al., (2021), os índices calculados a partir das bandas do Sentinel-2A que mais se destacaram foram: NDVI, EVI e DVI. No modelo de predição produzido por Boulihim (2024), os índices que mais contribuíram para o desempenho do modelo foram: RVI, NDVI, CVI e SAVI.

Uma variável que influencia nos valores de MOS disponíveis nos primeiros horizontes do solo é o uso da terra. Como a área de estudo é uma área úmida, ela apresenta um padrão heterogêneo, com uma variabilidade lateral das características do solo. Wei

Zhang et al., 2012 estudaram uma depressão cárstica com o mosaico de usos entre cultivo e pastagem. Descreveram a área de estudo como complexa e concluíram em seu trabalho que as variáveis auxiliares, como NDVI e topografia, melhoram o desempenho da krigagem de COS. Segundo Wang (2019), para reduzir o RMSE da modelagem de MOS em pastagens não podem ser ignoradas as características como clima e relevo. O autor encontrou uma correlação alta com o NDVI e concluiu que as modelagens multifatoriais apresentam RMSE mais baixos.

A principal diferença entre os resultados deste trabalho e os dos autores citados acima é que o NDVI não se apresentou como uma das principais variáveis para explicar o modelo, e os valores de RMSE foram significativamente maiores. As particularidades de cada área de estudo deixam as diferenças mais acentuadas: como a região de área úmida apresenta um solo mais úmido e maiores quantidades de MOS, provavelmente a maior opacidade do *pixel* fez com que os índices de mais destaque na predição de MOS nessa paisagem fossem: FEIRON, FE, MSI, SBIMSS, SOIL e VARI.

### **5.3 Cálculo de MOS em pequenas áreas úmidas por RPAS**

As imagens do RPAS são produto de um sensor RGB, faixa que envolve todo o espectro que o sensor CMOS consegue abranger (400 nm a 750 nm) e que é considerada curta. Neste trabalho, o modelo de predição do RPAS teve o valor mínimo de 25,25 g/kg e o valor máximo, de 48,92 g/kg de MOS. Esse intervalo está próximo dos dados coletados, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg. A acurácia do modelo resultou em uma correlação positiva, com o  $R^2$ : 0,88. O erro quadrado foi de RMSE: 3,62, o erro médio absoluto MAE: 2,85 e o erro quadrático médio foi de MSE: 13,11.

Zheng et al., (2024), utilizando o RPAS DJI M300 acoplado com o sensor hiperespectral Cubert S185, produziu um modelo de predição de MOS com 40 amostras para uma área de 6,5 hectares, obtendo  $R^2$  de 0,42 e RMSE de 0,77. No trabalho de Zheng et al., (2024), os autores concluem que a presença de umidade nas áreas úmidas fez com que o modelo não-linear tivesse maior acurácia que o modelo linear.

Sun et al., (2022) produziram um modelo de predição de MOS com 108 amostras de solo em uma área de 1.000 km<sup>2</sup>, obtendo, para calibração, um  $R^2$  de 0,663 e um RMSE de 5,263 e, para validação, um  $R^2$  de 0,656 e um RMSE de 5,325. No trabalho de Sun et

al., (2022), os dados espectrais foram extraídos de imagens LANDSAT 8 e das imagens de drone Dajiang Matrice 600 Pro UAV, acoplado com o sensor GaiaSky.

Neste trabalho, os resultados alcançados pelo modelo RPAS tiveram uma performance mais baixa do que os resultados alcançados pelo Sentinel-2A. Na seleção das variáveis calculadas já se observou uma variabilidade menor; além disso, apesar de ter melhor resolução, as bandas disponibilizam uma faixa espectral mais curta, apresentando uma menor resposta espectral. No presente trabalho, o resultado do PCA do RPAS concluiu que apenas a primeira dimensão já explicaria o fenômeno, reforçando a falta de variabilidade dos dados, determinando que os índices que melhor explicam a primeira dimensão foram: CIVE, DAVI, EXG, EXGR, EXR, GLI, MGVRI, MPRI, NDI e RG.

A baixa variabilidade das variáveis calculadas com as bandas do RPAS ocorreu devido às limitações de análise quando se trata de imagens RGB. Uma importante limitação vem pelo fato de as bandas serem extremamente curtas, reduzindo drasticamente a capacidade de detecção por *pixel*.

Os resultados deste trabalho estão em consonância aos outros trabalhos, como o de Zheng et al., (2024), que também apontou o índice NDI como uma das variáveis que mais colaborou no modelo de previsão de MOS. Os valores de RMSE altos estão em consonância com os valores encontrados por Sun et al., (2022). Uma das interferências na resposta espectral citada pelo autor é da vegetação, que influi na precisão do modelo.

#### **5.4 Dificuldade de estimativas de MOS e importância da pesquisa**

Todos os métodos preditivos apresentam limitações, já que a qualidade da previsão depende do ajuste do modelo ao fenômeno estudado. Em muitos estudos de caso, a previsão de teores de MOS ou de COS a partir do sensoriamento remoto não foi considerada significativa, obtendo-se valores de dependência espacial baixos,  $R^2$  baixos e RMSE altos (Bernardi et al., 2014; Yuzugullu et al., 2020; Charishma et al., 2024). Yuzugullu et al., 2020 atribuem esta dificuldade ao fato de que os teores de MOS e a resposta espectral a ela associada são afetados por vários fatores como manejo, clima ou composição pedológica. Uma das maiores dificuldades em quantificar propriedades pedológicas através de sensores orbitais com imagens gratuitas reside na composição da paisagem envolvida em cada *pixel*; muitas vezes outros elementos que não o solo, dentro

do *pixel*, interfere nas respostas espectrais e na variabilidade dos dados, logo, interferem também na interpretação da assinatura espectral.

No presente estudo buscou-se a predição de MOS em uma área úmida. Nesses ambientes, espera-se que a cobertura vegetal reflita os diferentes graus de umidade do solo que, por sua vez, têm relação direta com a acumulação de MOS (Chapin III et al., 2002). Trata-se, portanto, de três variáveis relacionadas (características da cobertura vegetal, umidade do solo e MOS) mas que possuem comportamentos e tempos de resposta muito diferentes mediante as variações das condições do ambiente. Além disso, a área de estudo encontra-se significativamente modificada pela ação antrópica, inclusive com presença de espécies vegetais invasoras, o que pode interferir na resposta espectral da superfície. Tudo isso impõe limitações ao método. Resultados mais confiáveis podem ser obtidos em áreas de solo exposto (Castaldi et al., 2014), onde não há interferência da variável vegetação, entretanto isso não é possível para o tipo de ambiente aqui estudado, pois se tratar de área ambientalmente muito frágil e protegida pela legislação ambiental.

Considerando essas limitações e diante dos resultados obtidos nesta pesquisa com o modelo com Sentinel-2A, que forneceu valor mínimo de MOS de 22 kg/g e máximo de 47,66 g/kg, verificou-se proximidade em relação aos dados coletados em campo, que variaram entre o mínimo de 27,55 g/kg e o máximo de 42,07 g/kg, com  $R^2$ : 0,88, erro quadrado de RMSE: 3,62 e erro médio absoluto MAE: 2,649839. O modelo com o RPAS alcançou o valor mínimo de 25,25 g/kg e o valor máximo, de 48,92 g/kg de MOS, também próximo dos dados obtidos em campo, com  $R^2$ : 0,88, erro quadrado de RMSE: 3,62, erro médio absoluto de MAE: 2,85, e erro quadrático médio de MSE: 13,11. Pode-se considerar que o método foi satisfatório na predição dos teores de MOS dos solos da área úmida estudada.

A compreensão da distribuição espacial das propriedades do solo é fundamental para a gestão ambiental, para o levantamento dos solos, para o planejamento e para a produção agrícola. Como a informação qualitativa disponível nos mapas de solos é muitas vezes insuficiente para estratégias de gestão específicas do local relativas à água, fertilizantes, herbicidas ou colheita, muitas vezes é necessária a estimativa quantitativa das propriedades do solo (por exemplo, textura do solo, carbono orgânico, nitrogênio e umidade do solo) (Castaldi et al., 2016). Ainda segundo esses autores, citando Mulder et al., (2011), dados de sensoriamento remoto podem ser usados para se obter, de maneira

muito econômica, informações qualitativas e quantitativas sobre variáveis do solo e para classificação do solo.

Trabalhos que envolvam vegetações naturais sem muita alteração ou regiões com solo exposto, seriam relevantes para se comparar os valores espectrais e se comparar os diferentes métodos. Igualmente, um maior número de pontos de amostragem de solos em campo também seria desejável.

## CONSIDERAÇÕES FINAIS

A espacialização do modelo utilizando técnicas de Machine Learning, com destaque para o algoritmo *Random Forest* (RF), apresentou resultados alinhados com a realidade observada, alcançando o objetivo de desenvolver um modelo eficiente para a predição do teor de Matéria Orgânica do Solo (MOS) em áreas úmidas. O modelo demonstrou grande potencial na identificação de padrões espaciais da matéria orgânica, contribuindo para uma melhor compreensão das dinâmicas ambientais da área de estudo.

O objetivo geral desta pesquisa foi avaliar a viabilidade do uso de dados espectrais fornecidos pelo programa espacial Copernicus, por meio do satélite Sentinel-2A, disponibilizados gratuitamente pela plataforma *Google Earth Engine* (GEE), para estudos de predição e distribuição espacial do teor de matéria orgânica na camada superficial e imediatamente abaixo da superfície do solo, em uma área úmida isolada sobre uma superfície aplanada. Os resultados obtidos evidenciaram a robustez do método e a capacidade das ferramentas empregadas em gerar dados relevantes para a gestão e conservação de áreas ambientalmente sensíveis.

Como próximas etapas, recomenda-se a realização de testes com novos algoritmos, como redes neurais convolucionais (CNN), visando aprimorar a acurácia e a capacidade preditiva do modelo. Além disso, é pertinente explorar a aplicação do modelo em outras regiões para verificar sua reprodutibilidade, bem como desenvolver técnicas de *upscaling*, ampliando a escala de aplicação e integrando dados obtidos por *Remotely Piloted Aircraft System* (RPAS) com imagens de satélite. Estudos futuros também podem contemplar comparações entre áreas úmidas preservadas e degradadas, permitindo uma análise mais abrangente das condições ambientais.

### Referências Bibliográficas

ALVES, L. R. **Avaliação dos impactos ambientais na mata ciliar da cidade de Limeira-SP com análise da composição florística da APP.** Trabalho de Conclusão de Curso apresentado ao Instituto de Biociências da Universidade Estadual Paulista para obtenção do grau em Ecologia. Rio Claro, SP, 2022.

AHAMED. T., TIAN. L., ZHANG. Y., TING. K. C. A review of sensing methods for biomass feedstock production. **Biomass and Bioenergy.** p. 2455-2469. 2011.

ASLAN.M.F.; DURDU. A.; SABANCI.K.; ROPELEWSKA. E.; and GÜLTEKIN.S.S. A comprehensive survey of the recent studies with UAV for precision agriculture in open fields and greenhouses, **Appl. Sci.**, vol. 12, no. 3, p. 1047, 2022.

ATZBERGER, C.; DARVISHZADEH, R.; IMMITZER, M.; SCHLERF, M.; SKIDMORE, A.; LE MAIRE, G. Comparative analysis of different retrieval methods for mapping grassland leaf area index using airborne imaging spectroscopy. **Int. J. Appl. Earth Obs. Geoinf.** 2015, 43, 19–31

BALDOTTO. M. A. VELLOSO. A. C. X. Eletroquímica de solos modais e de sua matéria orgânica em ambientes tropicais. **Rev. Ceres, Viçosa**, v.16, n.6, p. 1012-1021, nov/dez, 2014.

BALDOTTO. M. A.; BALDOTTO. L. E. B. Relationships between soil quality indicators, redox properties, and bioactivity of humic substances of soils under integrated farming, livestock, and forestry. **Rev. Ceres.** Viçosa, v.65, n.4, p.373-380, jul/ago, 2018.

BENDIG. J.; YU. K.; AASEN. H.; BOLTEN. A.; BENNERTZ. S.; BROSCHEIT. J.; BARETH. G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, 39, pp. 79–87. 2015.

BERNARDI, A. C. C.; RABELLO, L. M.; INAMASU, R. Y.; GREGO, C. R.; ANDRADE, R. G. Variabilidade espacial de parâmetros físico-químicas do solo e biofísicos de superfície em cultivo do sorgo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, 2014, p. 623-630.

BERTRAND. G. Paisagem e Geografia Física Global. Esboço Metodológico. **Revista RA’EGA**, Curitiba, n.8, p. 141-152, 2004.

BOUSLIHIM.Y., JOHN.K., MIFTAH. A., AZMI.R., ABOUTAYEB.R., BOUASRIA.A., RAZOUK.R., HSSAINI.L., The effect of covariates on Soil Organic Matter and pH variability: a digital soil mapping approach using random forest model. **Annals of Gis.** p.215-232, n°2, vol. 30, 2024.

BHOWMIK, S. Ecological and economic importance of wetlands and their vulnerability: a review *Curr. State Future Impacts Clim.* **Change Biodivers.** 2020, p. 95-112.

BRISON. M. M. **A hydrogeomorphic classification for wetland.** Corps of Engineers Research, August, 1993.CANFIELD. D. E.; FARQUHAR. J. **The GlobalSulfur Cycle.** In *Fundamentals of Geobiology.* Ed: KNOLL. A. H.; CANFIELD. D. E.; KONHAUSER. K. O., 2012 DOI: <https://doi.org/10.1002/9781118280874.ch5>.

CASAGRANDE.M.F.S.; FURLAN.L.M.; MOREIRA. C.A.; ROSA. F. T. G.; ROSOLEN.V. Non-invasive methods in the identification of hydrological ecosystem services of a tropical isolated wetland (Brazilian Study Case), *Environmental Challenges*, 2021, DOI : <https://doi.org/10.1016/j.envc.2021.100233>.

CARVALHO M.L., MACIEL V.F., BORDONAL R.O., CARVALHO J.L.N., FERREIRA T.O. CERRI C.E.P. CHERUBIM M.R. Stabilization of organic matter in soils: drivers, mechanisms, and analytical tools—a literature review. **Revista Brasileira de Ciência do Solo**, 47, P. 1-33, 2023.

CASSIANO, F. L. **Diagnóstico e estratégia para o desenvolvimento rural sustentável sob a ótica da agroecologia para o município de Cordeirópolis/SP**. Dissertação apresentada ao Programa de Pós-Graduação em Agroecologia e Desenvolvimento Rural como requisito parcial à obtenção do título de mestre em agroecologia e desenvolvimento rural. Araras. Julho, 2013.

CASTALDI F.; PALOMBO A.; SANTINI F.; PASCUCCI S.; PIGNATTI S.; CASA R. Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon, **Remote Sensing of Environment**, vol. 179, 2016, p. 54-65.

CECCATO. P. GOBRON. N., FLASSE. S, PINTY. B., TARANTOLA. S. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1 Theoretical approach. **Remote Sensing of Environment**. 2002.

CHAPIN III, F.S.; MATSON, P.A.; MOONEY, H.A. **Principles of terrestrial ecosystem ecology**. New York: Springer-Verlag. 2002, 449 p.

CHARISHMA, D. S., KULIGOD, V. B., GUNDLUR, S. S., POTDAR, M. P., DODDAMANI, M. B., NAGAVENI, H. C. Estimation of top soil properties by Sentinel-2A imaging. **Geology, Ecology, and Landscapes**, 2024, p. 1-10.

CHEN. L.; REN. C.; Li. L.; WANG.Y.; ZHANG. B.; WANG. Z.; LIL. 2019. "A Comparative Assessment of Geostatistical, Machine Learning, and Hybrid Approaches for Mapping Topsoil Organic Carbon Content" *ISPRS International Journal of Geo-Information* 8, no. 4: 174. <https://doi.org/10.3390/ijgi8040174>

CHORLEY. R. J. *Geomorphology and general systems theory. Theoretical papers in the hydrologic and geomorphic sciences. Geological survey professional paper 500-B*. United states government printing office, washington: 1962.

CHRISTOFOLETTI, A. *Análise de sistemas em Geografia*. São Paulo, Editora Hucitec, 1979.

CHRISTOFOLETTI, A. *Modelagem de Sistemas Ambientais*. São Paulo, Editora Edgar Blucher, 1999.

COLANGELO, A. C. (2011). O Modelo De Feições Mínimas, Ou Das Unidades Elementares De Relevô: Um Suporte Cartográfico Para Mapeamentos Geológicos. **Revista Do Departamento De Geografia**,1996, 10, 29-40. <https://doi.org/10.7154/RDG.1996.0010.0003>.

COPERNICUS-DEM, GLO-30. 2024. <https://doi.org/10.5270/ESA-c5d3d65>

CPRM - SERVIÇO GEOLÓGICO DO BRASIL. Carta de suscetibilidade a movimentos gravitacionais de massa e inundação: município de Cordeirópolis, SP, 2017. In:< <https://rigeo.sgb.gov.br/handle/doc/17410>>.

CUNHA-SANTINO M.B.; BIANCHINI JR. Reviewing the organic matter processing by wetlands. **Acta Limnologica Brasiliensia**, vol. 35, 2023, P. 1-13.

DEMATTE. J. A. M., GENÚ. A. M., FIORIO. P. R., ORTIZ. J. L., MAZZA. J. A., LEONARDO. H. C. L. Comparação entre mapas de solos obtidos por sensoriamento remoto espectral e pelo método convencional. **Pesq. agropec. bras.**, Brasília, v.39, n.12, p.1219-1229, dez. 2004.

DIGNAC. M. F.; DERRIEN. D.; BARRÉ. P.; BAROT. S.; CÉCILLON. L.; CHENU. C.; CHEVALLIER. T.; FRESCHET. G.T.; GARNIER. P.; GUENET. B.; HEDDE. M.; KLUMPP. K.; LASHERMES. G.; MARON. P. A.; NUNAN. N.; ROUMET. C.; BASILE-DOELSCH. I. Increasing soil carbon storage: mechanisms, effects of agricultural practices and proxies. A review. **Agron Sustain Dev**. 37:14, 2017, P. 1-27.

DOGAN, H. M. Mineral composite assessment of Kelkit River Basin in Turkey by means of remote sensing. **Journal of Earth System Science**, 118, 701-710, 2009.

DUCHAUFOR.P. Pedology, Pedogenesis and classification, 1982, DOI: 10.1007/978-94-011-6003-2

DUCHAUFOR P. Précis de **Pédologie**. Paris: Masson, 1960, 438 p.

EMBRAPA. **Manual de métodos de análise de solo**. Embrapa Solos. Rio de Janeiro, 2011.

ESA. **The European Space Agency**. Visita: 17/05/2022. In: < <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>>

FALKOWSKI, Paul G. **The global carbon cycle: biological processes**. In: Fundamentals of Geobiology, First Edition. Blackwell Publishing Ltd. Published 2012.

FRANCESCHINI. M. H.; DEMATTÊ. J. A. M.; SATO. M. V.; VICENTE. L. E. e GREGO. C. R. Abordagens semiquantitativa e quantitativa na avaliação da textura do solo por espectroscopia de reflectância bidirecional no VIS-NIR-SWIR. **Pesq. agropec. Brasília**, v.48, n.12, p. 1569-1582, dez. 2013.

FURLAN LM, ROSOLEN V, MOREIRA CA, BUENO GT, FERREIRA ME. The interactive pedological-hydrological processes and environmental sensitivity of a tropical isolated wetland in the Brazilian Cerrado. **SN Appl. Sci**. 3, 2021, p. 1-15. L. S. Galvão & I. Vitorello (1998) Role of organic matter in obliterating the effects of iron on spectral reflectance and color of Brazilian tropical soils, International Journal of Remote Sensing, 19:10, 1969-1979, DOI: 10.1080/014311698215090

GALVÃO.L. S.; I. VITORELLO. (1998) Role of organic matter in obliterating the effects of iron on spectral reflectance and color of Brazilian tropical soils, International Journal of Remote Sensing, 19:10, 1969-1979, DOI: 10.1080/014311698215090

GENÚ. A. M.; DEMATTÊ. J. A. M.; FIORIO. P. R. Análise espectral de solos da Região de Mogi-Guaçu (SP). **Ciências Agrárias**, Londrina, v.31, suplemento 1, p. 1235-1244, 2010.

GITELSON. A. A., VINÃ. A. ARKEBEAUER. T. J., RUNDQUIST. D. C., KEYDAN. G., LEAVITT. B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, vol. 30. N°5, 1248, doi: 10.1029/2002GL016450, 2003.

GITELSON. A. A., KAUFMAN. Y. J., STARK. R., RUNDQUIST. D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, p. 76 - 78, 2002.

GMACH, M.R., CHERUBIN, M.R., KAISER, K., CERRI, C.E.P., 2020. Processes that influence dissolved organic matter in the soil: a review. **Scientia Agricola**, v. 77, n. 3, 2020, p.1-10.

GLENN. E., NAGLER. P. L. HUETE. A. R. Vegetation Index Methods for Estimating Evapotranspiration by Remote Sensing. **Serv Geophys**, 2010. DOI. 10.1007/s10712-010-9102-2.

GOBAT, J.M.; ARAGNO, M.; MATTHEY, W. **Le sol vivant: bases de pédologie, biologie des sols**. PPUR Presses polytechniques, Paris. 2010, 251p.

GOMES, S. C.; MAGALHÃES JÚNIOR, A. P. Sistemas de classificação de áreas úmidas no Brasil e no mundo: panorama atual e importância de critérios hidrogeomorfológicos. **Geo UERJ**, Rio de Janeiro, n.33, e, 34519,2018. DOI: 10.12957/geouerj.2018.34519. Disponível em: <https://www.e-publicacoes.uerj.br/index.php/geouerj/article/view/34519>. Acesso em: 07/julho/2021.

GODOY. R. M. P.; GOZZO. L. F.; LLOPART. M.; PERON. B. L.; REBOITA. M. S.; REPINALDO. H. F. B.; MARRAFON. V. H. A. M. Projeções Climáticas de Temperatura do Ar e Precipitação para o Estado de São Paulo utilizando o Modelo Regional RegCM4. **Anuário do Instituto de Geociências**, 2021, v.44, 39850.

Gulev, S.K., P.W. Thorne, J. Ahn, F.J. Dentener, C.M. Domingues, S. Gerland, D. Gong, D.S. Kaufman, H.C. Nnamchi, J. Quaas, J.A. Rivera, S. Sathyendranath, S.L. Smith, B. Trewin, K. von Schuckmann, and R.S. Vose, 2021: **Changing State of the Climate System. In Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change** [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 287–422, DOI : [10.1017/9781009157896.004](https://doi.org/10.1017/9781009157896.004).

HAGUE, T.; TILLET, N.D.; WHEELER, H. Automated crop and weed monitoring in widely spaced cereals. **Precis. Agric.** 2006, 7, 21–32.

HENRICH. V. S. C.; KRAUSS. G. List of available Indices, Index Database. In:<<https://www.indexdatabase.de/db/i.php>>, acesso em: Dec. 01, 2021.

HONG. Y.; CHEN.S.; LIU.Y.; ZHANG.Y.; YU.L.; CHEN.Y.; LIU.Y.; CHENG.H.; LIU.Y. Combination of fractional order derivative and memory-based learning algorithm to improve the estimation accuracy of soil organic matter by visible and near-infrared spectroscopy, **CATENA**, Volume 174,2019, Pages 104-116, ISSN 0341-8162.

HUETE. A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**. 25:295-309. 1988.

HUNT. E. R., ROCK. B. N. Detection of Changes in Leaf Water Content Using Near- and Middle-Infrared Reflectances. **Remote. Sens. Environ.** 1989. [https://doi.org/10.1016/0034-4257\(89\)90046-1](https://doi.org/10.1016/0034-4257(89)90046-1)

HUNT. E. R. ; CAVIGELLI. M. ; DAUGHTRY. C.S.T. ; MCMURTREY. J.E. ; WALTHALL. C.L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precis. Agric.**, 6(4).2005.

HUNT Jr. E. R. ; DAUGHTRY. C. S. T. ; EITEL. J. U. ; LONG. D. S. (2011). Remote sensing leaf chlorophyll content using a visible band index. **Agronomy journal**, 103(4), 1090-1099.

IBGE. **Enciclopédia dos Municípios Brasileiros**. Vol. 28, Rio de Janeiro: Gráfica do IBGE, 1957, 492 p.

IBGE. **Instituto Brasileiro de Geografia e Estatística**. Visita: 14/07/2023. In: < <https://cidades.ibge.gov.br/brasil/sp/cordeiropolis/panorama>>

ISAACS, E. H. **Applied geostatistics** / Edward H. Isaacs and R. Mohan Srivastava. p. cm. Bibliography: p. Includes index. ISBN 978-0- 19-605013-4

JUNQUEIRA, Deise Aparecida. **Princípios da governança ambiental na gestão de recursos hídricos com foco em áreas úmidas (AU's) na depressão periférica paulista**. 2021. Dissertação (Mestrado em Geociências e Meio Ambiente) – Instituto de Geociências, Universidade Estadual Paulista, Rio Claro, 2021.

KAUTH. R. J., THOMAS. G. S. The tasseles cap – a graphic description of the spectral-temporal development of agricultura crops as seen in Landsat. In : Symposium on Machine Processing of Remotely Sensed Data, 1976.

KLEIDON. A. Non-equilibrium thermodynamics, maximum entropy production and Earth-system evolution. **Phil. Trans. R. Soc. A** (2010) 368, 181–196. doi:10.1098/rsta.2009.0188.

KURSA. M. B. ; RUDNICKI. W. R. (2010). Feature selection with the Boruta package. *Journal of statistical software*, 36, 1-13.

KHAIER. F. Soil Salinity Detection Using Satellite Remote Sensing. **International Institute for Geo-information Science and Earth Observation Enschede, The netherlands**. March, 2003.

KUMAR. S.; LAL. R; LIU. D. A geographically wighted regression kriging approach for mapping soil organic carbon stock. **Geoderma.**, v.189-190, 2012, p.627-634.

LAL. R. Soil carbon sequestration to mitigate climate change. **Geoderma**. 2004. doi:10.1016/j.geoderma.2004.01.032.

LAL, Rattan. Accelerated Soil erosion as a source of atmospheric CO2. **Soil & Tillage Research**, 188 (2019) 35-40. Carbon Management and Sequestration Center, The Ohio State University, OH 43210, United States.

LEIBOWITZ S.G. Isolated wetlands and their functions: an ecological perspective. **Wetlands**, v. 23, n. 3, 2003, p. 517–531.

LORETI JUNIOR. R., SARDOU FILHO. R. **Polo cerâmico de Santa Gertrudes. Informe de Recursos Minerais, Série Rochas e Minerais Industriais**. Ministério de Minas e Energia. Secretaria de Geologia, Mineração e Transformação Mineral. Serviço Geológico do Brasil. São Paulo: CPRM, 2014.

LÜTZOW Mv, KÖGEL-KNABNER I, EKSCHMITT K, MATZNER E, GUGGENBERGER G, MARSCHNER B, FLESSA H. Stabilization of organic matter in temperate soils: mechanisms and their relevance under different soil conditions – a review. **Eur J Soil Sci.** 57, 2006, p. 426-445.

MARENGO, J. A.; ALVES, L. M. Crise hídrica em São Paulo em 2014: seca e desmatamento. **Geosp – Espaço e Tempo (Online)**, v.19, n.3, p. 485-494, mês. 2016. **ISSN 2179-0892**.

MAKARIEVA. A. M.; GORSHKOV. V. G. Biotic pump of atmospheric moisture and driver of the hydrological cycle on land. **Hydrology and Earth System Sciences.**, 11, 1013 -1033, 2007.

MENESES. P. R., ALMEIDA. T., BAPTISTA. G. M. M. **Reflectância dos Materiais Terrestres análise e interpretação**. São Paulo: Oficina de Textos, 2019. ISBN: 978-85-7975-301-5.

MEYER, G. E.; NETO, J. A. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and Electronics in Agriculture**. v. 63, n. 2, p. 282–293, 2008. DOI: <<http://doi.org/10.1016/j.compag.2008.03.009>>.

MITSCH. W. J. BERNAL. B.; NAHLIK. A. M. MANDER. U. ZANG. L. ANDERSON. C. J. JORGENSEN. S. E.; BRIX.H.; Wetlands, carbon, and climate change. **Landscape Ecology**, April, 2012.

MITSCH. W. J.; GOSELINK. J. G. **Wetlands**. Fifth edition. 2015. ISBN 978-1-118-67682-0.

MISHRA. S. P., SARKAR. U., TARAPHDER. S., DATTA S., SWAIN. D., Saikhom, R., ... & Laishram, M. (2017). Multivariate statistical data analysis-principal component analysis (PCA). **International Journal of Livestock Research**, 7(5), 60-78.

MORAIS. V. A., SILVA. C. A., SCOLFORO. J. R. S., MELLO. J. M., ARAÚJO. E. J. G., ASSIS. E. A. Modelagem do teor de carbono orgânico em solos de fragmentos de Cerrado e de Januária e Bonito de Minas, Minas Gerais. **Pesquisa Florestal Brasileira**, Colombo, v.33, n.76, p.343-354. 2013.

NASA. **ECOSTRESS Spectral Library** <<https://speclib.jpl.nasa.gov/library>>

OLLIS, D.J., SNADDON, C.D., JOB, N.M. & MBONA, N. 2013. **Classification System for Wetlands and other Aquatic Ecosystems in South Africa**. User Manual: Inland Systems. SANBI Biodiversity Series 22. South African National Biodiversity Institute, Pretoria. **ISBN 978-1-919976-75-4**.

PENTEADO. M. M. **Fundamentos de geomorfologia**. Fundação Instituto Brasileiro de Geografia e Estatística – IBGE, 1983. ISBN 85-240-0130-5. 3.ed. Rio de Janeiro, RJ – Brasil.

PEREIRA, Osvaldo José Ribeiro. **Mapping soil organic carbon storage in deep soil horizons of Amazonian Podzols**. 2015. Tese (Doutor em Ciências) – Centro de Energia Nuclear na Agricultura da Universidade de São Paulo, São Paulo, 2015.

PINHEIRO. M. R.; QUEIROZ NETO. J. P. Reflexões sobre a gênese da Serra Geral e da depressão periférica paulista: o exemplo da região da serra de São Pedro e do baixo do Piracicaba, SP. **Revista do Instituto Geológico**, São Paulo, 35(1), 47-59, 2014.

PIZARRO, M.A.; EPIPHANIO, J.C.N.; GALVÃO, L.S. Caracterização mineralógica de solos tropicais por sensoriamento remoto hiperespectral. **Pesq. agropec. bras.**, Brasília, v.36, n.10, p.1277-1286, out. 2001.

POLEY. G. L.; MCDERMID. J. G. A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems. **Remote Sensing**, 2020, 12(7), 1052.

POULADI. N.; MOLLER. A. B.; TABATABAI. S.; GREVE. M. H. Mapping soil matter contents at field level with Cubist, Random Forest and Kriging. **Geoderma**, 342, p.85-92, 2019.

PRIBYL, D.W. A critical review of the conventional SOC to SOM conversion factor. **Geoderma**. 2010, 156, 2010, p. 5-83.

RESENDE. T. M., ROSOLEN. V. Impactos da conversão de uso e manejo do solo do cerrado utilizando dados de carbono total e isotópico. **GEOUSP – espaço e tempo**, São Paulo, n°33, pp.39 – 52, 2013.

RIGHI D.; MEUNIER, A. Origin of clays by Rock weathering and soil formation. In: VELDE, B. **Origin and Mineralogy of Clays - Clays and the Environment**. Berlin: Springer-Verlag. 1995, p. 43-161.

RIZZO. R.; DEMATTÊ. J. A. M.; LACERDA. M. P. C. Espectros VIS-NIR do solo e fuzzy k-médias aplicados na delimitação de unidade de mapeamento de solos em topossequências. **R. Bras. Ci. Solo**, 39:1533-1543, 2015. DOI: 10.1590/01000683rbc20140694.

ROMAGNOLI. F., NANNI. M. R., GASPAROTTO. A. C., JUNIOR. C. A. S., CEZAR. E., SILVA. A. A., SACIOTO. M. Predição do carbono do solo por meio de análise multivariada e sensoriamento remoto. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.

ROLIM.G.S.; CAMARGO.M.B.P.; LANIA.D.G.; MORAES.J.F.L. Classificação climática de köppen e de thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de são paulo. **Bragantia**. Campinas, v.66, n.4, p.711-720, 2007.

ROWAN.L.C., MARS. J. C. Lithologic mapping in the Mountain Pass, California area using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data. **Remote Sensing of Environment**. 2003. p.350 -366.

RONDEAUX. G., STEVEN. M., BARET. F. Optimization of Soil-Adjusted Vegetation Indices. **Remote Sens. Environ.** 1996.

ROUSE. J. W., HASS. R. H., SHELL. J. A., DEERING. D. W. Monitoring vegetation systems in the great plains with ERTS. Third Earth Res. Technol. Satellite. Symp. Vol. 1, 309-317, 1973.

ROUSE. J.W. ; HAAS. R.W. ; SCHELL. J.A. ; DEERING. D.W. ; HARLAN. J.C. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. NASA Goddard Space Flight Center: Houston, TX, USA. **Texas A&M University. Remote Sensing Center.** 1974. <https://ntrs.nasa.gov/search.jsp?R=19730017588>. Accessed on 1 April 1973.

ROSS, J.L.S.; MOROZ I.C. **Mapa Geomorfológico do Estado de São Paulo**. Escala 1:500.000. São Paulo, 2 vols. 1997.

ROWAN.L.C., MARS. J. C. Lithologic mapping in the Mountain Pass, California area using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data. **Remote Sensing of Environment**. 2003. p.350 -366.

RUSSEL. M., CHO. M. A., MATHIEU. R., O'KENNEDY. M. M. , KOCH. A. R. S. K. An investigation into robust spectral indices for leaf chlorophyll estimation. **ISPRS Journal of Photogrammetry and Remote Sensing**. 2011, p.751-761.

SANTOS, F. A. **Rio Claro: uma cidade em transformação (1850-1906)**. São Paulo: Annablume, 2002. 206 p.

SENTINEL-2\_TEAM. **Sentinel-2 user handbook**. European Space Agency, 2015.

SEGARRA. J.; BUCHAILLOT. M. L., ARAUS. J. L., KEFAUVER. S. C. Remote sensing for precision agriculture: Sentinel-2 improved features and applications, **Agronomy**, vol. 10, no. 5, p. 641, 2020.

SILVA-SANGOI. D. V.; HORST. T. Z.; MOURA-BUENO. J. M.; DALMOLIN. R. S. D.; SEBEM. E.; GLEBER. L.; SANTOS. M. S. Soil Organic matter and clay prediction by laboratory spectroscopy: Data spatial correlation. **Geoderma Regional**, 2022.

SOLLINS, P.; HOMANN, P.; CALDWELL, B.A. Stabilization and Destabilization of Soil Organic Matter Mechanisms and Controls. **Geoderma**, 74, 2006, p. 65-105.

SOUZA.S.C.P.M.; CIELO-FILHO.R.; BAITELLO.J.B.; AGUIAR.O.T.; PASTORE.J.A.; FRANCO.G.A.D.C.; TONIATO.M.T.Z.; BARBOSA.A.C.O.; LIMA. C.R.; COSTA.N.O.; PINTO.N.S. Caracterização Florística de uma área de contato entre Cerrado e Mata Atlântica na região sudoeste do estado de São Paulo. **Rev. Inst. Flor.** v.24, n.1, p.99-132, jun. 2012.

SOUZA, C.M., Jr.; Z. SHIMBO, J.; ROSA, M.R.; PARENTE, L.L.; A. ALENCAR, A.; RUDORFF, B.F.T.; HASENACK, H.; MATSUMOTO, M.; G. FERREIRA, L.; SOUZA-FILHO, P.W.M.; et al., Reconstructing Three Decades of Land Use and Land Cover

Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sens.** 2020, 12, 2735. <https://doi.org/10.3390/rs12172735>

SUN. M.; LI. Q.; JIANG. X.; YE. T.; LI. X.; NIU. B. Estimation of Soil Salt Content and Organic Matter on Arable Land in the Yellow River Delta by Combining UAV Hyperspectral and Landsat-8 Multispectral Imagery. **Sensors.** 2022, 22, 3990. <https://doi.org/10.3390/s22113990>

TARDY, Y. *Pédrologie des latérites et des sols tropicaux.* Paris: Masson, 1993, 459 p.

TINER R. W. Geographically isolated wetlands of the United States. **Wetlands**, v. 23, no. 3, 2003, p. 494-516.

TÔSTO. S. G.; PEREIRA. L. C.; PAIVA SOBRINHO. R.; MARQUES. J. F.; ROMEIRO. A. R.; MANGABEIRA, J. A. Análise multicritério com apoio à elaboração de índice de sustentabilidade ambiental no município de Araras, SP. Campinas: Embrapa Monitoramento por Satélite, 2010.

TUCKER, Compton J. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. **Remote Sensing of Environment**, [s.l.], v. 8, n. 2, p. 127-150, 1979.

USGS. U.S. Geological Survey. Visita: 21/05/2022. In:< [https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2#overview 2](https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2#overview-2)>.

VIEIRA. P. H. VIEIRA. A. C. A. S. A atividade minerária e sua relação no aumento da fragilidade ambiental no município de Cordeirópolis – SP. **Revista Geografar**, Curitiba, v.14, n.1, p.108-130, jan. a jun./2019.

YAMAMOTO. J. K., LANDIM. P. M. B. **Geoestatística: Conceitos e aplicações.** São Paulo: Oficina de Textos, 2013.

WINTER, T.C.; LABAUGH J.W. Hydrologic considerations in defining isolated wetlands. **Wetlands** 23, 2003, p. 532-540.

WOEBBECKE, D. M.; MEYER, G. E.; V. B. K.; MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. **Trans. ASAE**, v. 38, p. 259-269. 1995.

WOEBBECKE, D. M.; MEYER, G. E.; VON BARGEN, K.; MORTENSEN, D. A. Plant species identification, size, and enumeration using machine vision techniques on near-binary images. **Optics in Agriculture and Forestry**, v. 1836, p. 208-219, 1992. DOI: <http://dx.doi.org/10.1117/12.144030>.

YUZUGULLU O, LORENZ F, FRÖHLICH P, LIEBISCH F. Understanding Fields by Remote Sensing: Soil Zoning and Property Mapping. **Remote Sensing.** 12(7):1116, 2020, p. 1-20.

ZECH. W.; SENESI. N.; G. GUGGENBERGER.; KAISER. K.; LEHMAN. J.; MIANO. T. M.; MILTNER. A.; SCHROTH. G. Factors controlling humification and mineralization of soil organic matter in the tropics. **Geoderma.** 1997.

ZHANG. J.; QIU. X.; WU. Y.; ZHU. Y.; CAO. Q.; LIU. X.; CAO. W. Combining texture, color, and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods. **Computers and Electronics in Agriculture**, 185, 2021, 106138.

ZHENG. G.; CHEN. T.; WANG. Y.; LI. X.; DAI. W.; XU. M.; JIAO. C.; ZHAO. C. Rapid monitoring of the spatial distribution of soil organic matter using unmanned aerial vehicle vehicle imaging spectroscopy. **Annals of gis**, 2024, vol.30, p.367-381.