UNIVERSIDADE DO ESTADO DE MATO GROSSO

FACULDADE DE CIÊNCIAS BIOLÓGICAS E AGRÁRIAS

PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E AGROECOSSISTEMAS AMAZÔNICOS

DETECÇÃO DE ÁREAS DE MILHO POR MEIO DE ANÁLISE ORIENTADA EM GEO-OBJETO UTILIZANDO MULTI-SENSORES ORBITAIS NA PLATAFORMA GOOGLE EARTH ENGINE

ALTA FLORESTA-MT

2023

2 cm	15 cm	7 cm	5 cm
	ISMAEL CAVALCANTE MACIEL JUNIOR	Diss. MESTRADO	PPGBioAgro 2023

1 2 3 4 5

UNIVERSIDADE DO ESTADO DE MATO GROSSO
FACULDADE DE CIÊNCIAS BIOLÓGICAS E AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E AGROECOSSISTEMAS AMAZÔNICOS

ISMAEL CAVALCANTE MACIEL JUNIOR

DETECÇÃO DE ÁREAS DE MILHO POR MEIO DE ANÁLISE ORIENTADA EM GEO-OBJETO UTILIZANDO MULTI-SENSORES ORBITAIS NA PLATAFORMA GOOGLE EARTH ENGINE

Dissertação apresentada à Universidade do Estado de Mato Grosso, como parte das exigências do Programa de Pós-Graduação em Biodiversidade e Agroecossistemas Amazônicos, para a obtenção do título de Mestre em Biodiversidade e Agroecossistemas Amazônicos.

Orientador: Prof. Dr. Carlos Antonio da Silva Junior

ALTA FLORESTA-MT

2023

AUTORIZO A DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO, CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Catalogação na publicação

Faculdade de Ciências Biológicas e Agrárias

J95d MACIEL JUNIOR, Ismael Cavalcante.

Detecção de áreas de milho por meio de análise orientada em geo-objeto utilizando multi-sensores orbitais na plataforma Google Earth Engine / Ismael Cavalcante Maciel Junior – Alta Floresta, 2023.

74 f.; 30 cm. (ilustrações) II. Color. (sim)

Trabalho de Conclusão de Curso
(Dissertação/Mestrado) – Curso de Pós-graduação Stricto Sensu
(Mestrado Acadêmico) Biodiversidade e Agroecossistemas Amazônicos, Faculdade de Ciências Biológicas e Agrárias, Câmpus de Alta Floresta, Universidade do Estado de Mato Grosso, 2023.

Orientador: Carlos Antonio da Silva Junior

1. Texturas GLCM. 2.Random Forest. 3.Segmentação SNIC. I. Ismael Cavalcante Maciel Junior. II. Detecção de áreas de milho por meio de análise orientada em geo-objeto utilizando multi-sensores orbitais na plataforma Google Earth Engine:.

CDU 528

DETECÇÃO DE ÁREAS DE MILHO POR MEIO DE ANÁLISE ORIENTADA EM GEO-OBJETO UTILIZANDO MULTI-SENSORES ORBITAIS NA PLATAFORMA GOOGLE EARTH ENGINE

ISMAEL CAVALCANTE MACIEL JUNIOR

Dissertação apresentada à Universidade do Estado de Mato Grosso, como parte das exigências do Programa de Pós-Graduação em Biodiversidade e Agroecossistemas Amazônicos, para a obtenção do título de Mestre em Biodiversidade e Agroecossistemas Amazônicos.

Aprovada em: 28/02/2023

_____

Prof. Dr. Carlos Antonio da Silva Junior

Orientador – UNEMAT/ PPGBioAgro

_____

Prof. Dr. Rivanildo Dallacort

UNEMAT/ PPGBioAgro

_____

Prof. Dr. Cácio Luiz Boechat

UFPI

DEDICATÓRIA

Dedico esta dissertação a Deus e minha família, sem os quais não haveria capacidade nem motivação para realizar projetos como esse.

Dedico também a meu pai Ismael Cavalcante Maciel e a meu sogro João José da Silva, *in memorian*, homens que foram e sempre serão minhas referências.

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus, minha fonte.

Agradeço a minha graciosa esposa Marcela pelo encorajamento nos momentos difíceis e pelas revisões ao longo dessa elaboração e ao meu filho Nicolas que esteve todo esse trajeto ao meu lado, me incentivando e animando mesmo sem perceber. Para vocês entrego o meu melhor!

Quero também agradecer a Conab, que em parceria com a Universidade Estadual de Mato Grosso (UNEMAT) e o Professor Dr. Carlos Antonio da Silva Junior me permitiu chegar até aqui.

Agradeço ao meu orientador, professor Dr. Carlos Antônio da Silva Junior pelo interesse no desenvolvimento desse trabalho, que devido à dificuldade de locomobilidade quase se viu interrompido, não fosse ponderado pelo próprio orientador. Meus sinceros agradecimentos!

Agradeço a todos os professores que ministraram as disciplinas, pelo empenho e dedicação na orientação em todos os momentos desse mestrado. De igual modo, agradeço aos membros da banca pela disponibilidade.

Desejo igualmente agradecer aos meus amigos Raul e Rogério pela cooperação em todas as etapas dessa jornada e ainda a todos colegas do Mestrado em Biodiversidade e Agroecossistemas Amazônicos e do laboratório de Geotecnologia Aplicada em Agricultura e Floresta (GAAF).

A todos vocês, os meus sinceros agradecimentos!

“A sabedoria oferece proteção, como o faz o dinheiro, mas a vantagem do conhecimento é esta: a sabedoria preserva a vida de quem a possui.”

Eclesiastes 7:12

SUMÁRIO

LISTA DE TABELAS vii

LISTA DE FIGURAS viii

LISTA DE SIGLAS (ou de ABREVIATURAS) x

RESUMO xii

ABSTRACT xiii

1. INTRODUÇÃO 1

2. OBJETIVO GERAL E ESPECÍFICOS 3

2.1. Objetivo Geral 3

2.2. Objetivos Específicos 3

3. REVISÃO DA LITERATURA 4

3.1 Cultura do milho no Brasil 4

3.1.1 Fases fenológicas 5

3.2 Sensoriamento remoto agrícola 7

3.2.1 Mapeamento de alvos agrícolas 8

3.2.2 Comportamento espectral da vegetação agrícola 9

3.3 Sensores orbitais 12

3.3.1 Sentinel 2A-B 12

3.3.2 Landsat-8 13

3.3.3 Terra e Aqua 15

3.3.4 Sistema Planet 16

3.4 Processamento digital de imagens 18

3.4.1 Classificação supervisionada 18

3.4.2 Processo de segmentação na identificação de alvos 19

3.4.3 Análise Orientada em Geo-Objeto 21

3.4.3.1 Cor, textura, tamanho e forma 23

3.4.4 Classificador *Random Forest* (RF) 24

4. METODOLOGIA E DELINEAMENTO DA PESQUISA 26

4.1. Área de estudo 26

4.2. Pré-processamento 28

4.3. Segmentação e classificação 31
4.4. Validação da classificação 34
5. RESULTADOS E DISCUSSÃO 38
6. CONCLUSÃO 55
7. SUGESTÃO PARA TRABALHOS FUTUROS 56
7. REFERÊNCIAS BIBLIOGRÁFICAS 57

LISTA DE TABELAS

TABELA 1: Variação dos Componentes Principais do PCA dos 4 sensores... 42

TABELA 2: Acurácias Global (AGs) e índices Kappa da classificação dos 4 sensores analisados..... 49

TABELA 3: Áreas (ha) das classes classificadas nos 4 sensores analisados. 52

TABELA 4: Análise de Variância (ANOVA) com 5% de probabilidade realizada para os resultados de Acurácia Global e índice Kappa das classificações dos 4 (quatro) sensores 53

TABELA 5: Comparação múltipla de médias pelo teste de Tukey HSD (5% de probabilidade) realizada para os resultados de Acurácia Global e índice Kappa das classificações dos quatro sensores 53

LISTA DE FIGURAS

FIGURA 1: Mapa de localização do município de Canarana. Fonte: IBGE. Elaboração: o autor 26
FIGURA 2: Biomas em Mato Grosso e Canarana. Fonte: IBGE. Elaboração: o autor 27
FIGURA 3: Mapa de Aptidão Agrícola para o município de Canarana. Fonte: PRONASOLOS. Elaboração: o autor 28
FIGURA 4: Cobertura pantropical do programa NICFI. Fonte: Planet NICFI ... 29
FIGURA 5: Pontos geográficos de diversos usos do solo em Canarana-MT. Fonte: o autor 35
FIGURA 6: Fluxograma da metodologia da classificação orientada a objeto no GEE. Fonte: o autor 37
FIGURA 7: Declividade do terreno em Canarana, utilizando 12% de declividade como limite entre áreas mecanicamente agricultáveis e não agricultáveis. Fonte: o autor 38
FIGURA 8: Mosaicos das imagens utilizadas na classificação de uso e ocupação do solo em Canarana-MT: (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Imagens Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 39
FIGURA 9: Índices de vegetação obtidos por meio do Sensor OLI Landsat-8: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor 40
FIGURA 10: Índices de vegetação obtidos por meio do Sensor MODIS Terra: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor 40
FIGURA 11: Índices de vegetação obtidos por meio das imagens Planet NICFI: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor 41
FIGURA 12: Índices de vegetação obtidos por meio do Sensor MSI Sentinel-2: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor 41
FIGURA 13: Mosaico das Análises de Componentes Principais (PCAs): (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Imagens Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 43
FIGURA 14: Imagens segmentadas pelo algoritmo SNIC no Google Earth Engine (GEE): (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Imagens Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 44

FIGURA 15: Teste de acurácia com diferentes números de árvores de decisão no Random Forest: (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Imagens Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 45
FIGURA 16: Importância de cada banda das imagens para a classificação de uso e ocupação do solo: (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Imagens Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 45
FIGURA 17: Matriz de Confusão para Sensor OLI Landsat-8. Fonte: o autor . 47
FIGURA 18: Matriz de Confusão para o Sensor MODIS Terra. Fonte: o autor 47
FIGURA 19: Matriz de Confusão para o Sensor Planet NICFI. Fonte: o autor 48
FIGURA 20: Matriz de Confusão para o Sensor MSI Sentinel-2. Fonte: o autor 48
FIGURA 21: Classificação de Uso e Ocupação do solo utilizando a metodologia GEOBIA com o classificador Random Forest para os quatros sensores avaliados: (A) Sensor OLI Landsat-8, (B) Sensor MODIS Terra, (C) Sensor Planet NICFI e (D) Sensor MSI Sentinel-2. Fonte: o autor 49
FIGURA 22: Recorte das áreas de milho 2ª safra classificadas pelo Sensor OLI Landsat-8. Fonte: o autor 50
FIGURA 23: Recorte das áreas de milho 2ª safra classificadas pelo Sensor MODIS Terra. Fonte: o autor 50
FIGURA 24: Recorte das áreas de milho 2ª safra classificadas pelo Sensor Planet NICFI. Fonte: o autor 51
FIGURA 25: Recorte das áreas de milho 2ª safra classificadas pelo Sensor MSI Sentinel-2. Fonte: o autor 51

LISTA DE SIGLAS (ou de ABREVIATURAS)

AC Acurácia do Usuário ou do Consumidor

AG Acurácia Global

AP Acurácia do Produtor

API Application Programming Interface

ARVI Atmospherically Vesistant Vegetation Index

CART Classification and Regression Tree

CCF Conteúdo de Clorofila Foliar

CONAB Companhia Nacional de Abastecimento

CWC Crop Canopy Water Content

DISS Dissimilarity

EMBRAPA Empresa Brasileira de Pesquisa Agropecuária

ESA Agência Espacial Europeia

EVI Enhanced Vegetation Index

GEE Google Earth Engine

GLCM Gray Level Co-occurrence Matriz

ha Hectare(s)

IA Inteligência Artificial

IAF Índice de Área Foliar

IAV Índice de Área Verde ou Índice de Área Vegetal

IBGE Instituto Brasileiro Geografia e Estatística

IDM Inverse Difference Moment

IVs Índices de Vegetação

LSWI Land Surface Water Index

MAPA Ministério da Agricultura, Pecuária e Abastecimento

MDE Modelo Digital de Elevação

MODIS Moderate Resolution Imaging Spectroradiometer

MSI Multispectral Instrument

NASA Administração Nacional da Aeronáutica e Espaço

NDVI Normalized Difference Vegetation Index

NDWI Normalized Difference Water Index

NICFI Norway's International Climate and Forests Initiative

NIR Infravermelho Próximo

OLI Operational Land Imager

PCA Análise de Componentes Principais

PCEI Índice de Melhoramento de Cultura Perpendicular

PL PlanetScope

PPGBioAGRO Programa de Pós-graduação em Biodiversidade e Agroecossistemas Amazônicos

PRONASOLOS Programa Nacional de Solos do Brasil

PRPPG Pró-reitoria de Pesquisa e Pós-graduação

PVI Perpendicular Vegetation Index

RF Random Forest

RFA Radiação Fotossinteticamente Ativa

RFAa Radiação Fotossinteticamente Ativa Absorvida

RGB Red Green Blue

SAVI Soil Adjusted Vegetation Index

SCSc Solar Canopy Sensor + C

SENT Soma da Entropia

SLIC Simple Linear Iterative Clustering

SNIC Simple Non-Iterative Clustering

SUDAM Superintendência do Desenvolvimento da Amazônia

SWIR Infravermelho de Ondas Curtas

TIRS Thermal Infrared Sensor

USGS Serviço Geológico dos Estados Unidos

VIS Domínios Espectrais Visíveis

Vis Ultravioleta Visível

ZARC Zoneamento Agrícola de Risco Climático

MRS Multi-Resolution Segmentation Method

HSEG Hierachical Segmentation

RESUMO

MACIEL JUNIOR, Ismael Cavalcante. M.Sc. Universidade do Estado de Mato Grosso, fevereiro de 2023. **Detecção de áreas de milho por meio de análise orientada em geo-objeto utilizando multi-sensores orbitais na plataforma Google Earth Engine**. Orientador: Carlos Antônio da Silva Junior.

O estado de Mato Grosso é o maior produtor de milho no país, tendo a predominância de cultivo concentrando na segunda safra. Diante do anseio de obter dados mais precisos e eficientes, a inteligência agrícola está se adaptando e adotando novas tecnologias, como o uso de satélites para sensoriamento remoto e sistemas de informações geográficas. Nesse contexto, este estudo teve como objetivo mapear as áreas de milho de segunda safra no município de Canarana-MT, utilizando uma análise orientada em geo-objeto com diferentes resoluções espaciais, espectrais e temporais. Os sensores Sentinel-2A/B (MSI), Landsat-8 (OLI), Terra/Aqua (MODIS) e PlanetScope (PS) foram utilizados para esse fim. Foi realizado um estudo para mapear áreas de milho em Canarana-MT usando a base cartográfica do IBGE e o Google Earth Engine (GEE). Foram aplicados filtros nas imagens e adicionados quatro índices de vegetação. Recursos texturais foram usados para a etapa de segmentação, que foi realizada com o algoritmo Simple Non-Iterative Clustering (SNIC). O Random Forest (RF) foi usado para a classificação das imagens. A análise da matriz de confusão e estatísticas de validação foram realizadas com 2.200 amostras de campo. Após a realização desses procedimentos, os dados classificados geraram matrizes de confusão com Acurácia Global (AG) variando de 86,41% a 88,65% e índice Kappa entre 81,26% e 84,61%. As avaliações realizadas mostraram resultados satisfatórios, já que tanto o índice Kappa quanto a AG apresentaram valores superiores a 80% em todos os sensores avaliados. Concluindo-se, portanto, que a metodologia GEOBIA, utilizando a combinação SNIC + GLCM com o classificador RF na plataforma GEE, foi satisfatória para mapear as áreas de milho de segunda safra no município de Canarana-MT.

Palavras-chave: Texturas GLCM, Random Forest, Segmentação SNIC.

ABSTRACT

MACIEL JUNIOR, Ismael Cavalcante. M.Sc. Mato Grosso State University, february 2023. **Detection of maize areas through geo-object oriented analysis using orbital multi-sensors on the platform Google Earth Engine**. Advisor: Carlos Antônio da Silva Junior.

The state of Mato Grosso is the largest corn producer in the country, with the predominance of cultivation concentrated in the second crop. In order to obtain more precise and efficient data, agricultural intelligence is adapting and adopting new technologies, such as the use of satellites for remote sensing and geographic information systems. In this context, this study aimed to map second-crop corn areas in the municipality of Canarana-MT, using a geo-object oriented analysis with different spatial, spectral, and temporal resolutions. The Sentinel-2A/B (MSI), Landsat-8 (OLI), Terra/Aqua (MODIS), and PlanetScope (PS) sensors were used for this purpose. A study was conducted to map corn areas in Canarana-MT using the cartographic database from IBGE and Google Earth Engine (GEE). Filters were applied to the images and four vegetation indices were added. Texture features were used for the segmentation step, which was performed with the Simple Non-Iterative Clustering (SNIC) algorithm. Random Forest (RF) was used for image classification. Confusion matrix analysis and validation statistics were performed with 2,200 field samples. After these procedures, the classified data generated confusion matrices with Global Accuracy (GA) ranging from 86.41% to 88.65% and Kappa index between 81.26% and 84.61%. The evaluations showed satisfactory results, as both the Kappa index and GA presented values above 80% in all evaluated sensors. Therefore, it was concluded that the GEOBIA methodology, using the SNIC + GLCM combination with the RF classifier on the GEE platform, was satisfactory for mapping second-crop corn areas in the municipality of Canarana-MT.

Key-words: GLCM Textures, Random Forest, SNIC segmentation.

1. INTRODUÇÃO

O estado do Mato Grosso é o maior produtor de milho do país, conforme aponta a Companhia Nacional de Abastecimento (Conab) em seu 12º levantamento da safra brasileira de grãos (2021/22) com uma área de aproximadamente 6,55 milhões de hectares (ha) e 41,62 milhões de toneladas (t) de grãos produzidos. Vale ainda destacar que apesar do grande consumo interno a maior parte da produção é destinada às exportações, que vem batendo recordes nos últimos anos (COMEXSTAT, 2021). No âmbito estadual, a predominância de cultivo se concentra na segunda safra, denominada milho safrinha, que corresponde aproximadamente a 99% da área destinada à cultura do cereal (CONAB, 2022). Diante da grande produção, a estimativa das áreas cultivadas é importante para que o suprimento da demanda nacional e a capacidade de transporte e armazenamento não sejam comprometidas (BERTOLIN et al., 2017).

As estimativas oficiais de safras no Brasil são levantadas de forma subjetiva pela Conab e pelo Instituto Brasileiro Geografia e Estatística (IBGE). Os levantamentos realizados por agentes técnicos sobre as áreas plantadas, produção e dados econômicos para a maioria das culturas agrícolas por meio de entrevistas com produtores, vendas de insumos e fertilizantes, entre outros, geram dados com pouca confiabilidade (OLDONI, 2018). As visitas a campo para a coleta de informações ocorrem em baixa frequência e ainda estão sendo gradualmente reduzidas pela escassez de recursos financeiros e humano. Outrossim, a grande extensão territorial do estado de Mato Grosso deixa o processo da pesquisa oneroso e demorado. Assim, deve-se buscar meios para aprimorar os atuais métodos subjetivos para estimativa da produção por novas tecnologias como imagens de satélites de sensoriamento remoto e os Sistemas de Informações Geográficas (SIGs) para estimativa de produção (PINO, 2001). Em comparação com outros setores produtivos, as atividades agrícolas considerando suas peculiaridades enfrentam questões específicas e, assim, necessitam ser monitoradas frequentemente e em escalas de abrangência municipais, regionais, nacionais e até globais (OLDONI et al., 2020; PRUDENTE et al., 2020).

O sensoriamento remoto e o geoprocessamento constituem-se em técnicas fundamentais para a manutenção de registros do uso da terra ao longo do tempo, pois permitem avaliar as mudanças ocorridas na paisagem de uma região e registrando a cobertura vegetal em cada momento (KHADIM et al., 2019). Ao longo do tempo, essas imagens podem gerar séries históricas importantes para a identificação da dinâmica das culturas em uma resolução espacial que permita intervenções em nível de agricultura de precisão (SPERANZA; GREGO; GEBLER, 2022).

O surgimento de várias plataformas de computação em nuvem, com o armazenamento de imagens captadas por uma gama de sensores dos satélites, amplia o acesso a imagens gratuitas para subsidiar as mais diversas pesquisas que vão desde desastres naturais, planejamentos urbanos, agricultura, entre outras aplicações. O *Google Earth Engine* é um exemplo de plataforma em nuvem para análise geoespacial em escala planetária que traz enormes recursos integrados projetados para capacitar não apenas cientistas, mas também, um público mais amplo que não possui capacidade técnica para utilizar supercomputadores tradicionais (GORELICK et al., 2017). O programa possui arquivos robustos dos satélites *Sentinel*, *Landsat* e *Terra/Aqua*, além de fornecer condições para o desenvolvimento de algoritmos geoespaciais que envolvem grandes conjuntos de dados (GOOGLE EARTH ENGINE, 2023).

Em face a crescente importância econômica do milho, é substancial que haja a veracidade de informações relativas à extensão das zonas cultivadas as quais são amplamente divulgadas pelas estimativas oficiais de área e produção agrícola realizadas pelo IBGE e pela Conab. Contudo, detecta-se atualmente a existência de diferenças entre estimativas publicadas pelos órgãos supracitados, que puderam ser constatadas na safra 2019/20, na qual a Conab estimou a área de 5.414,4 mil ha (CONAB, 2022), enquanto o IBGE conjecturou 5.337,3 mil ha para cultivo de milho segunda safra em Mato Grosso (SIDRA, 2020). Essa disparidade entre áreas é um dos fatores que contribuem para a diferença na produção do cereal em aproximadamente 930 mil toneladas apenas no estado, montante expressivo para o mercado, e que vem suscitando incertezas no setor quanto aos números divulgados pelos órgãos oficiais.

2. OBJETIVO GERAL E ESPECÍFICOS

2.1. Objetivo Geral

Objetiva-se realizar o mapeamento do milho safrinha no município de Canarana-MT mediante aplicação da metodologia GEOBIA com diferentes resoluções espaciais, espectrais e temporais, valendo-se dos sensores: *Sentinel-2A/B* (MSI), *Landsat-8* (OLI), *Terra/Aqua* (MODIS) e *PlanetScope*.

2.2. Objetivos Específicos

- Avaliar o uso de diferentes tipos de sensores remotos, com resoluções espaciais, espectrais, temporais e radiométricas diversas;
- Analisar a capacidade dos sensores remotos Sentinel-2A/B (MSI), Landsat-8 (OLI), Terra/Aqua (MODIS) e PlanetScope em estimar a área cultivada com milho;
- Processar e analisar as imagens da área de estudo utilizando a metodologia GEOBIA e o classificador Random Forest;
- Gerar um mapa das áreas cultivadas com milho de segunda safra.

3. REVISÃO DA LITERATURA

3.1 Cultura do milho no Brasil

O milho (*Zea mays L.*) é uma espécie pertencente à família das gramíneas com registros de cultivo há mais de 8000 anos, atualmente produzido em várias partes do mundo face à sua grande adaptabilidade e a uma enorme gama de genótipos responsáveis por permitir o agricultar em variadas altitudes e climas (BARROS; CALADO, 2014). O milho possui grande importância tanto na alimentação humana quanto à animal, devido ao seu elevado valor nutricional como também por seu baixo custo, consolidando-se assim como um dos cereais mais cultivados no mundo (GALVÃO et al., 2014).

Os primeiros dados de cultivo no Brasil datam de 1942, em quais a área estimada era de 4,06 milhões de hectares, majoritariamente semeadas na 1ª safra (cultivo de verão), apresentando produção total de 5,28 milhões de toneladas (IBGE, 1947). Em 1977, ano em que a Conab iniciou o acompanhamento da safra, a área com o cereal era de 11,80 milhões de hectares com produção de 19,26 milhões de toneladas (CONAB, 2022). A partir de 1979/80, o milho de 2ª safra, comumente denominado milho safrinha, passou a ser cultivado no país, no entanto em proporção relativamente pequena se comparado ao cultivo de 1º ciclo. A inversão de área ocorreu em 2011/12, em qual o espaço destinado ao grão na 1ª safra foi de 33,87 milhões de hectares em contraponto com 39,11 milhões na 2ª safra. Com o passar dos anos, a área com o milho safrinha passou a crescer exponencialmente com registros de cultivos de 3ª safra a partir da temporada 2018/19, com o milho safra perdendo espaço principalmente para a soja (CONAB, 2022; MIRANDA, 2019). De acordo com o 4º Boletim da safra brasileira publicado pela Conab, as áreas da safra 2021/22 destinada à cultura do milho foi de 4,55, 16,37 e 0,66 milhões de hectares para a 1ª, 2ª e 3ª safra, respectivamente (CONAB, 2023).

Ao longo desses 80 anos de cultivo no Brasil, a evolução da área plantada elevou-se em 531,55%, e a produção em 2.142,68%. Esse incremento deve-se principalmente ao aumento da produtividade que no período apresenta um acréscimo de 403,08%, face o desenvolvimento de pesquisas, tecnologias, cultivares, formação de profissionais e informação ao produtor rural através da extensão rural (CONAB, 2023; GALVÃO et al., 2014).

3.1.1 Fases fenológicas

Devido as modificações ocorridas nos processos de desenvolvimento da cultura, como germinação, brotação, florescimento, espigamento e maturação, surgiram divisões nesses processos, que são denominados de estádios fenológicos, cujo propósito é melhorar a descrição e o detalhamento das etapas de desenvolvimento do ciclo da cultura (BERGAMASCHI et al., 2006; WAGNER et al., 2011). A divisão dos estádios apresentados na cultura do milho é comumente dividida em cinco períodos: (1) germinação e emergência; (2) desenvolvimento vegetativo; (3) floração; (4) frutificação e (5) maturação fisiológica (GADIOLI et al., 2000; WAGNER et al., 2011).

A fase de germinação e emergência é de fato uma das mais importantes para o sucesso de uma lavoura de milho, pois é nela que se determina o primeiro e um dos mais importantes fatores de rendimento, que é a densidade de plantas por hectare. A emergência ocorre entre 4 e 5 dias após a semeadura em condições adequadas de temperatura e umidade do solo (WEISMANN, 2008).

O estádio de desenvolvimento vegetativo abrange as fases Vegetativa 1 (V1) a Vegetativa 18 (V18), nos quais o número seguido da letra “V” indica a quantidade de folhas da planta completamente desenvolvidas. O estádio V3 ocorre aproximadamente duas semanas após a emergência a depender do genótipo cultivado, e nessa fase a planta começa a formar e a definir a quantidade de folhas e espigas que eventualmente irá produzir. Nas fases V6 a V8, denominadas como estádio do “cartucho”, nas quais o ponto de crescimento e o pendão já estão acima do nível do solo é caracterizada pela queda das primeiras folhas e pela definição do número de fileiras de grãos nas espigas. Nos estádios V10 a V17 inicia-se o período que pode ser considerado o mais crítico para a produção, pois será definido o número de óvulos (grãos em potencial) em cada espiga, assim como o tamanho da espiga (WEISMANN, 2008).

A fase de floração é conhecida como VT, e pode ser caracterizada quando o último ramo do pendão (inflorescência masculina) está completamente visível e os “cabelos” não tenham ainda emergido da espiga. A emissão do pendão acontece de 2 a 4 dias antes da exposição dos “cabelos”. De 10 a 12 dias após o aparecimento do pendão, cerca de 70% das espigas apresentam

exposição dos cabelos. O período de liberação do pólen estende-se por 1 ou 2 semanas. Durante esse tempo, cada "cabelo" individual deve emergir e ser polinizado para resultar em um grão. Geralmente a liberação do pólen ocorre nos finais das manhãs e no início das noites, período em que as temperaturas são mais amenas. Neste período, em que a planta atingiu o máximo de desenvolvimento e crescimento, o estresse hídrico e temperaturas elevadas (acima de 35 ºC) podem reduzir drasticamente a produção, devido ao dessecamento tanto do grão de pólen como dos “cabelos” da espiga (WEISMANN, 2008).

A fase de frutificação abrange os estádios R1 ao R5. O embonecamento e polinização (R1) é o momento em que os estilos estigmas “cabelo” estão fora da espiga. A polinização ocorre quando o grão de pólen liberado é capturado por um dos estilos-estigmas. No estádio R2 os grãos apresentam-se brancos na aparência externa e com aspectos de uma bolha d'água, já no R3 (grão leitoso) a planta define a densidade de grãos, ocorrendo um rápido acúmulo de matéria seca com cerca de 80% de umidade. Esta fase de grão leitoso tem seu início aproximadamente entre 12 e 15 dias após a polinização, o grão apresenta-se com uma aparência amarelada, e em seu interior, contém um fluído de consistência leitosa. O grão pastoso (R4) é alcançado com cerca de 20 a 25 dias após a emissão dos estilos-estigmas, os grãos continuam desenvolvendo-se rapidamente e acumulando amido. O fluído interno dos grãos passa de um estado leitoso para uma consistência pastosa. A ocorrência de adversidades climáticas, sobretudo falta de água, resultará numa maior porcentagem de grãos leves e pequenos, o que comprometeria definitivamente a produção. A formação do dente (R5) é marcada pelo aparecimento de uma concavidade na parte superior do grão, comumente designada de o "dente", onde os grãos encontram-se em fase de transição do estado pastoso para o farináceo (WEISMANN, 2008).

O estádio de maturação fisiológica (R6) é atingido quando todos os grãos na espiga alcançaram o máximo peso seco e vigor, e a principal característica encontra-se na linha do amido que já avançou até a espiga e a camada preta já foi formada. Nessa fase, além da paralisação total do acúmulo de matéria seca nos grãos, verifica-se também o início do processo de

senescência natural das folhas das plantas, as quais gradativamente começam a perder a sua coloração verde característica (WEISMANN, 2008).

3.2 Sensoriamento remoto agrícola

O sensoriamento remoto surgiu como uma alternativa relativamente rápida e econômica para a coleta de dados espaciais e detém potencial para caracterização da superfície terrestre em larga escala por meio da observação da distribuição espaço-temporal (SARWAR et al., 2021). Essa tecnologia é amplamente utilizada em muitos campos que recolhe uma ampla gama de observações em um tempo hábil utilizando uma coleta de dados menos restrita (LIU et al., 2019), empregando o posicionamento global e informação geográfica, para produzir dados variados espacialmente, que são fundamentais para o sucesso da atual agricultura de alta tecnologia (HUANG et al., 2018).

O sensoriamento remoto permite obter informações sobre a agricultura regularmente com abordagens de medição não destrutivas (OLDONI et al., 2020). A partir de então, tem sido bastante aplicada no meio produtivo para mapear e monitorar áreas de cultivo, detectar a distribuição das culturas, prever a produção futura de alimentos sob diferentes cenários, tudo isso, baseado em grande parte no controle remoto óptico sensorial uma vez que as imagens óticas são facilmente interpretadas, especialmente para culturas em terras secas (LIU et al., 2019; SHI et al., 2014; SOJAMAPS, 2021). Para a obtenção desses resultados geralmente é utilizado uma combinação de diferentes características dos sensores remotos de modo a construir relações com os parâmetros biofísicos e/ou ecofisiológicos da cultura, tais como: índice de área foliar, biomassa, teor de clorofila, conteúdo de água da planta, entre outros fatores (SILVA JUNIOR et al., 2018; LIU et al., 2019).

Os grandes volumes de dados gerados pelo sensoriamento remoto da observação da terra e resultados de análises diárias a partir das plataformas de satélites, aeronaves tripuladas e não tripuladas têm se tornado uma das bases para a tecnologia na agricultura de precisão, que considera a variabilidade de campo para a gestão específica dos locais (HUANG et al., 2018). Os recentes avanços no sensoriamento remoto e Inteligência Artificial (IA) possibilitam quantificar à escala de campo informações fenotípicas com precisão além de

integrar os grandes dados em ferramentas de gestão preditiva e prescritiva (JUNG et al., 2021).

3.2.1 Mapeamento de alvos agrícolas

Face à evolução dos sistemas agrícolas torna-se necessário o emprego de técnicas cada vez mais avançadas para compreender e monitorar as mudanças na vegetação a fim de obter diagnósticos mais rápidos e precisos, visando maior rentabilidade, à vista disso, o aperfeiçoamento das tecnologias de sensoriamento remoto e geoinformática que incluem métodos de classificação supervisionados e não supervisionados têm contribuído muito para esse processo (FONSECA et al., 2021). Diversas plataformas de sensores combinadas ao desenvolvimento de técnicas de coleta e análise de dados de sensoriamento remoto vêm sendo empregadas para coletar e obter modelos precisos na estimação dos parâmetros de cultura, como desenvolvimento vegetativo e fitossanitários (WIJESINGHA et al., 2021).

O monitoramento das áreas agrícolas por meio de imagens orbitais é profícuo, em virtude de possuir características espectrais favoráveis para identificar, discriminar e quantificar áreas de cultivo, como: caracterizar o relevo; extensão territorial de ampla diversidade de culturas; distinguir estádios fenológicos e estimar produtividade por teor de clorofila, entre outros (JUNIOR et al., 2019; SILVA JUNIOR et al., 2014). Outro importante aspecto, concerne-se a utilização dessa ferramenta pelos órgãos oficiais nas estimativas da safra agrícola nacional, resultando em maior confiabilidade (precisão) e a oportunidade (momento de divulgação) das informações públicas a serem publicadas, diminuindo assim a utilização de dados subjetivos empregados atualmente (ADAMI et al., 2010).

A obtenção da informação em escala de paisagem das mais variadas culturas aliada a vasta extensão territorial em um período específico da produção agrícola tem sido desafiador em virtude da elevada dinâmica espaço-temporal da atividade agrícola, da falta de disponibilidade de imagens de alta resolução espacial ou a dificuldade de obtenção destas livres de nuvens, o que acaba por restringir todo o potencial ao uso operacional dos dados a apenas algumas regiões e culturas (ADAMI et al., 2010; ADUVUKHA et al., 2021).

Embora a disponibilidade de imagens oriundas de novos sensores com características apropriadas ao mapeamento agrícola e as evoluções no que dizem respeito ao conhecimento tecnológico, um dos maiores entraves em discriminar áreas utilizando imagens de baixa resolução espacial de regiões agricultoras com pequenas lavouras - principalmente pela agricultura familiar, são os *pixels* mistos que provocam um sério impacto na precisão das classificações (SILVA JUNIOR et al., 2017; WU; LI, 2012). Já em áreas agrícolas com maior extensão territorial, o problema de identificação é minimizado, uma vez que os *pixels* mistos são menos frequentes.

Durante o desenvolvimento das culturas, as lavouras agrícolas apresentam padrões dinâmico-temporais peculiares de imagens orbitais e exibem comportamento espectral versátil, em razão da variabilidade de fatores como: solo exposto, preparo do solo, tipo de plantio, vigor vegetativo, lavoura em senescência, entre outros (BERNARDES et al., 2011). Entretanto, os alvos agrícolas apresentam padrões fenológicos que as distinguem espectralmente de demais classes vegetais, possibilitando o mapeamento dessas áreas (SILVA JUNIOR et al., 2017).

Os principais métodos utilizados atualmente no mapeamento agrícola por sensoriamento remoto são: análise dos principais componentes, orientação sobre geo-objeto, índice de vegetação e classificação automática (IMANNI et al., 2022; POORTINGA et al., 2021; SILVA JUNIOR et al., 2017; VIZZARI, 2022a).

3.2.2 Comportamento espectral da vegetação agrícola

Os sensores artificiais captam as variações de intensidade da luz refletida do objeto na forma de várias bandas contínuas de comprimento de onda que variam do ultravioleta (espectro visível) ao infravermelho próximo, e às bandas de ondas infravermelhas de onda curta, e assim discriminam diferentes objetos (RYU; OH; CHO, 2021).

Na agricultura, silvicultura e outras ciências relacionadas à vegetação, o espectro de reflexão tem sido utilizado em diversas aplicações como a identificação de espécies, a avaliação da saúde vegetal que incluem comportamentos de cultivo causados por fatores abióticos e bióticos (doença,

água e estresse térmico), a quantificação da biomassa e produção e os estágios de crescimento e fenologia (RYU; OH; CHO, 2021).

Apesar do sensoriamento remoto possibilitar formas de obtenção de informações precisas sobre as extensas áreas das práticas agrícolas utilizando energia eletromagnética refletida particularizando a informação espaço-temporal, muitas vezes é difícil distinguir os diferentes tipos de práticas agrícolas ou ainda identificar sistemas agrícolas específicos. O comportamento estocástico ou à similaridade nas assinaturas espectrais de diferentes componentes do meio produtivo pode resultar em classificações errôneas do espaço (LIMAN HAROU et al., 2020; WIJESINGHA et al., 2021).

As resoluções espaciais, espectrais e temporais de uma imagem são fatores importantes para a análise precisa e interpretação correta dos dados acerca das culturas agrícolas. A resolução espacial varia drasticamente dependendo da plataforma do sensor, e está relacionada com capacidade da identificação de um objeto na imagem (SILVA JUNIOR et al., 2020).

Na resolução espectral, o sensoriamento remoto agrícola tem se valido tradicionalmente de imagens multiespectrais e hiperespectrais de diferentes plataformas com resoluções espectrais (ou largura de banda) de várias centenas de nanômetros, e normalmente está nas regiões do Ultravioleta Visível (Vis) e Infravermelho Próximo (NIR) de 400 a 1000 nm, faixa em qual as plantas apresentam assinaturas espectrais distintas sob condições diferentes (SILVA JUNIOR et al., 2020).

Enquanto os sensores hiperespectrais capturam a energia refletida em muitas bandas espectrais estreitas (geralmente mais de 30 bandas), os sensores multiespectrais contêm menos bandas e, consequentemente, maior largura da resolução espectral (SILVA JUNIOR et al., 2020). Deste modo, a imagem hiperespectral oferece maior potencial de extração de informações mais detalhadas em aplicações agrícolas devido a maior sensibilidade das faixas espectrais (THENKABAIL; LYON; HUETE, 2018; WIJESINGHA et al., 2021). A resolução temporal diz respeito ao tempo de aquisição e ao intervalo de tempo entre as aquisições de imagens (THENKABAIL; LYON; HUETE, 2018).

As assinaturas espectrais podem ser registradas a partir de imagem hiperespectral tanto aérea (fotogrametria de veículos aéreos não tripulados)

quanto espacial (imagens de satélite) (JANOUŠEK et al., 2021), ou por meio sensores portáteis instalados no campo. Ambos os tipos de dados espectrais têm potencial para atuar independentemente, mas também podem ser reciprocamente complementares (KUMAR et al., 2013; UPADHYAY et al., 2020), além disso, são também amplamente utilizados para avaliação dos traços bioquímicos, biofísicos e estruturais da vegetação através da análise de suas assinaturas espectrais. A absorção, reflexão e dispersão da luz das plantas ou qualquer objeto é descrita por seu padrão de reflexão, índice de refração espectral e um parâmetro que caracteriza a estrutura da folha (RYU; OH; CHO, 2021).

Os Índices de Vegetação (IVs) possuem amplo uso na agricultura e são calculados a partir das capturas espectrais das culturas com métodos matemáticos, e são capazes de refletir a situação de crescimento da vegetação como métrica simples e empírica (YUAN, Ningge et al., 2021). Esses índices podem ser definidos como a combinação aritmética entre duas ou mais bandas espectrais relacionadas às características de refletância da vegetação, pois são comumente proporcionais aos valores de vários parâmetros biofísicos, tais como biomassa e rendimento de culturas (VENANCIO et al., 2020).

Muitos parâmetros de vegetação da cultura que indicam crescimento e estado fitossanitário são estimados usando dados espectrais como: índice de Área Foliar (IAF), Conteúdo de Clorofila Foliar (CCF), e Conteúdo de Água da Copa das Folhas, Crop Canopy Water Content (CWC). Ao ser considerada outras partes da planta fotossinteticamente ativa, além das folhas, o estimador passa a ser denominado de Índice de Área Verde ou Índice de Área Vegetal (IAV).

Para tais análises, exige-se o diagnóstico do acúmulo de biomassa através do processo fotossintético, pois estão relacionadas à absorção de radiação pelas plantas, faixa conhecida como radiação fotossinteticamente ativa (RFA). No entanto, apenas parte da radiação é absorvida e aproveitada no processo fotossintético, sendo necessário a estimativa da radiação absorvida pelas plantas, conhecida como radiação fotossinteticamente ativa absorvida (RFAa), sendo determinada pelo balanço entre a radiação recebida subtraindo as frações transmitidas e refletidas para o ambiente (FONTANA et al., 2012).

3.3 Sensores orbitais

Nos últimos anos, uma série de sensores remotos de órbita baixa, menos de 1.000 km de altitude, se tornaram disponíveis, proporcionando grandes avanços na qualidade das resoluções espaciais, temporais e espectrais, e fornecendo novos métodos de observação para obtenção de dados globais de observação da Terra diariamente. Ao emparelhar a altíssima resolução temporal destes novos sensores com sensores compatíveis de baixa órbita terrestre é apresentada uma chance única de adquirir observações quase simultâneas de dupla visão, oportunizando o aumento no conteúdo de informação (QIN; MCVICAR, 2018; YUAN; LIAO, 2020).

A capacidade de detectar e quantificar mudanças no ambiente terrestre depende formalmente de sensores que possam fornecer medições calibradas e consistentes das características da superfície ao longo do tempo (CHANDER et al., 2010).

Os sensores de observação da Terra por satélite fornecem dados para compreensão da extensão espacial e temporal da cobertura terrestre. As imagens de satélites com alta resolução espacial e boa frequência de revisita são ferramentas imprescindíveis para o monitoramento agrícola operacional, avaliação e previsões de rendimento das culturas (CABALLERO; NAVARRO, 2021; CAMACHO et al., 2021).

3.3.1 Sentinel 2A-B

A Agência Espacial Europeia (ESA) desenvolveu a plataforma *Sentinel* para atender às necessidades operacionais do projeto *Copernicus*, que é o programa de Observação e Monitoramento da Terra da União Europeia, mediante o qual, é fornecido livre acesso a diversos dados operacionais e históricos para fundamentar aplicações e suprir serviços a uma ampla gama de áreas de benefícios sociais (LAMQUIN et al., 2019).

Cada missão *Sentinel* é baseada em uma constelação de dois satélites para cumprir os requisitos de revisita e cobertura (CABALLERO; NAVARRO, 2021; CABALLERO; STUMPF, 2019), fornecendo conjuntos de dados robustos, oportunos, contínuos e independentes sobre o uso da terra como recurso,

incluindo o monitoramento da vegetação, cobertura de solo e água, bem como observação de vias navegáveis e áreas costeiras do interior (SENTINEL, 2021).

A missão Sentinel-2 é uma constelação de satélites idênticos denominados *Sentinel-2A* e *Sentinel-2B* na mesma órbita a 180° entre si. Os dois satélites operacionais (A/B) oferecem um tempo potencial de revisita de cinco dias com seus *Multispectral Instruments* (MSI) em resolução espacial de 10, 20 e 60 m e resolução radiométrica de 12 *bits*. A cobertura do Sentinel-2 está entre as latitudes 56º sul e 84º norte. O sensor MSI de ambas as plataformas adquirem medições em 13 bandas espectrais de 443 nm a 2190 nm, nos Domínios Espectrais Visíveis (VIS), Infravermelho Próximo (NIR) e Infravermelho de Ondas Curtas (SWIR). A constelação ainda possui três resoluções espaciais, com quatro bandas a 10 m, seis bandas a 20 m e três bandas a 60 m, sobre uma largura total de faixa de 290 km (CABALLERO; STUMPF, 2019; CHASTAIN et al., 2019; LAMQUIN et al., 2019; SUN et al., 2019).

O lançamento do *Sentinel-2A* ocorreu em 23 de junho de 2015 e o *Sentinel-2B* em 7 de março de 2017, o 2A tornou-se disponível pela primeira vez em outubro de 2015, com coleta rotineira de dados de dez dias repetidos um ano depois (CABALLERO; STUMPF, 2019; CHASTAIN et al., 2019).

Assim sendo, desde o início de 2017, a missão *Sentinel-2* viabiliza o monitoramento contínuo de superfícies terrestres e águas costeiras em escala global, com imagens captadas pelos MSIs dos sensores *Sentinel-2A/B* com ciclo de revisita relativamente curto (em torno de 5 dias no Equador) e maior resolução (até 10 m) (CABALLERO; NAVARRO, 2021; JIN et al., 2021; LAMQUIN et al., 2019). Baseado em todas essas características, os dados do *Sentinel-2 A/B* também podem proporcionar cobertura global periódica e seus dados são disponibilizados gratuitamente para os usuários (WANG et al., 2021).

3.3.2 Landsat-8

A plataforma Landsat-8 foi desenvolvida como colaboração entre a NASA e o Serviço Geológico dos Estados Unidos (USGS), sendo lançada da Base Aérea de Vandenberg, Califórnia, em 4 de fevereiro de 2013, possui dois novos instrumentos de varredura: um *Thermal Infrared Sensor* (TIRS) e um *Operational Land Imager* (OLI), que podem se complementar na cobertura

espectral (CHASTAIN et al., 2019; GARCÍA, 2021; GHREFAT et al., 2021; LANDSAT-8, 2021; SUN, Deyong et al., 2021).

Os instrumentos do *Landsat-8* apresentam um avanço evolutivo na tecnologia em relação às gerações passadas, pois o novo sensor OLI possuí uma abordagem técnica demonstrada por um sensor *push-broom* com um telescópio de quatro espelhos e quantização de 12 *bits* (LANDSAT-8, 2021). Cada imagem *Landsat-8* inclui 11 bandas espectrais com uma largura de faixa de 185 km, sendo 8 bandas (bandas 1-7 e 9) com resolução espacial de 30 m, 1 banda com resolução de 15 m (banda 8), e 2 bandas térmicas (bandas 10 e 11) com resolução de 100 m (GARCÍA, 2021; GHREFAT et al., 2021; SUN, Deyong et al., 2021; UNAL CILEK; CILEK, 2021).

As imagens Landsat-8 são uma das fontes de dados mais utilizadas para monitoramento global, devido à cobertura de repetição de longo prazo e resolução espacial relativamente fina (WANG, Qunming et al., 2021b), e os seus dados estão disponíveis publicamente desde maio de 2013, com um tempo de revisita de 16 dias (CAMACHO et al., 2021).

O lançamento do Landsat-9 ocorreu em 21 de setembro de 2021, este se juntou ao *Landsat-8*, substituindo o *Landsat-7* lançado no ano de 1999. Os planos atuais exigem que o *Landsat-7* seja rebaixado para uma órbita diferente antes que o novo *Landsat* alcance sua ascensão final (LANDSAT-9, 2021; MASEK et al., 2020).

A combinação do *Landsat-8* com o *Landsat-9* assegura um tempo de revisita de coleta de dados de oito dias, possibilitando a aquisição de imagens de alta qualidade sem interferência de nuvens, o que atualmente é encarado como o maior entrave no mapeamento das culturas de verão. Esses eventos proporcionam um suporte para áreas atuais de aplicação em cobertura de terra, ciência criosférica e ecologia, ao mesmo tempo em que suportam melhor as aplicações de monitoramento da qualidade da água, da evapotranspiração e da bioquímica do dossel (MASEK et al., 2020).

O *Landsat-9*, como o *Landsat-8*, conta com uma maior capacidade de imagem além de ser radiometricamente e geometricamente melhor que os *Landsats* anteriores (LANDSAT-9, 2021). Embora concebido como um clone próximo do Landsat-8, o Landsat-9 oferece melhorias importantes, como a

redução da luz perdida TIRS-2, permitindo ainda a geolocalização mais precisa e resolução radiométrica de 14 *bits* completos de precisão radiométrica do OLI-2, além de fornecer um sinal melhorado para ruído para alvos mais escuros (MASEK et al., 2020).

3.3.3 Terra e Aqua

O *Moderate Resolution Imaging Spectroradiometer* (MODIS) é um instrumento-chave a bordo dos satélites Terra (originalmente EOS AM-1) e Aqua (originalmente EOS PM-1). Essas plataformas da Administração Nacional da Aeronáutica e Espaço (NASA) foram lançadas em dezembro de 1999 (Terra) e maio de 2002 (Aqua). Os satélites Terra e Aqua têm uma órbita quase polar síncrona ao sol, são cronometrados de modo que o Terra se desloque de Norte a Sul através do Equador pela manhã, enquanto Aqua passa de Sul para Norte sobre o Equador à tarde (CROSSON et al., 2012; NASA, 2021; WANG, Lili et al., 2010). Devido à distinção de direção, as diferenças de tempo de latitude média entre as plataformas são de aproximadamente 1,5 h no Hemisfério Norte e 4,5 h no Hemisfério Sul (KHAROL et al., 2011).

A combinação do MODIS Terra e Aqua MODIS permite a visualização de toda a superfície da Terra a cada 1 a 2 dias com uma largura de faixa de visualização de 2.330 km, adquirindo dados em 36 bandas espectrais com quantização de 12 *bits* em diferentes resoluções espaciais, sendo: 250 m (bandas 1-2), 500 m (bandas 3-7), 1000 m (bandas 8-36) (CROSSON et al., 2012; DUVEILLER et al., 2021; NASA, 2021).

As observações adquiridas desses dois instrumentos MODIS são de extrema relevância para a compreensão da dinâmica global e dos processos que ocorrem em terra, oceanos e na atmosfera inferior, pois foram especificamente projetados para monitorar vários constituintes atmosféricos da Terra em uma escala temporal quase diária, tendo utilidade em muitas aplicações e em várias disciplinas, a destacar o mapeamento de grandes áreas agrícolas (BRIGHT; GUEYMARD, 2019; SILVA JUNIOR et al., 2017; MASEK et al., 2020).

O sensor MODIS tem uma configuração de alcance espectral semelhante ao sensor ETM+ do *Landsat-7*, no entanto suas imagens têm uma

resolução espacial mais grosseira em comparação às imagens ETM+ (WANG, Qunming et al., 2021a).

Apesar dessa resolução ser considerada grosseira para várias aplicações devido à heterogeneidade espacial predominante em muitas paisagens, uma aplicação proeminente é o monitoramento agrícola, onde o uso bem-sucedido de séries temporais específicas da cultura requer isolar apenas os *pixels* que caem adequadamente nos campos apropriados usando informações acessórias em resolução espacial mais fina, além de fornecer resolução temporal quase diária, representando um ponto positivo na obtenção de imagens sem nuvens (SILVA JUNIOR et al., 2017; DUVEILLER et al., 2021). Outro aspecto relevante é que as imagens adquiridas por esses satélites estão disponíveis em várias fontes a todos os usuários para as mais diversas aplicações (NASA, 2021).

A utilização dos padrões fenológicos identificados a partir de séries temporais MODIS-Terra/Aqua combinado com o *Enhanced Vegetation Index* (EVI) de 250 m têm sido amplamente utilizados para classificar culturas de soja, milho e algodão. Além disso, as imagens desses sensores aliadas a outros índices de vegetação juntamente com imagens de outros satélites, como *Landsat-8* e *Sentinel-2*, mostram-se relevantes para classificar várias categorias de vegetação, como classes de floresta e pastagem (BELGIU; CSILLIK, 2018).

3.3.4 Sistema Planet

A empresa *Planet* (antiga *Planet Labs*) possui uma plataforma comercial que consiste em 150-200 nano-satélites em órbita, considerada como a maior constelação de microssatélites do mundo, coletando imagens multiespectrais em quatro bandas de alta resolução diariamente a baixo custo. O sistema possui três constelações distintas de satélites (*Dove, SkySat e RapidEye*), porém opera atualmente com duas constelações. A *Planet* adquiriu a constelação *RapidEye* em 2015, possuindo um dos maiores arquivos de imagens de 5 m de resolução, porém foi aposentada em março de 2020, devido a vida útil do projeto que durou cerca de onze anos (CHENG, Tao et al., 2020; PLANET, 2021).

A constelação *Dove* é composta de vários minissatélites, denominados *Doves*, e pesam aproximadamente 5 kg com dimensões de 10x10x30 cm. São normalmente lançados ao espaço em grandes lotes, e os primeiros *Doves* que estão orbitando a Terra foram lançados em dezembro de 2015, varrendo a Terra com cenas individuais dimensionadas em aproximadamente 24x7 km (PLANET, 2021). Por ter taxa de revisita diária oferece mais oportunidades para imagens livres de nuvens nas regiões de interesse (LI et al., 2019), gerando cenas com resoluções espaciais de 3 a 5 m (BHUSHAN et al., 2021; HOUBORG; MCCABE, 2018).

A constelação *SkySat* é formada por vinte e um (21) satélites encarregados de filmar qualquer ponto da Terra em altíssima resolução (50 cm), podendo capturar imagens estéreo e filmagens de vídeo por até 90 segundos, e cada imagem do *SkySat* cobre cerca de 70 quilômetros quadrados. Os *SkySats*, como são chamados cada satélite dessa constelação, dispõem de um sistema de propulsão individual que permite mantê-los em uma altitude desejada e otimizar a cobertura global, propiciando focalizar as áreas de maior interesse (PLANET, 2021). Os *SkySats* podem ser operados em vários modos de aquisição, incluindo mono, estéreo triplo e coleção de vídeo. Os produtos de cada modo de aquisição são compostos por muitas "cenas" sobrepostas adquiridas por alguns ou todos os três detectores (BHUSHAN et al., 2021).

A *Planet* possui uma plataforma de imagens e análises automatizadas baseada em nuvem, permitindo ao usuário baixar, processar e gerenciar os dados disponíveis, fornecendo dados prontos para análise, sem necessidade de pós-processamento ou intervenção manual. Além disso, a *Planet* se integra diretamente com uma gama de softwares geoespaciais combinando as imagens da plataforma com os ambientes de conteúdo e análise, sendo as principais: Esri ArcGIS Pro, QGIS e o *Google Earth Engine* (GEE) (PLANETSCOPE, 2021).

Por fim, os satélites que compõem cada constelação têm resoluções espaciais, temporais e radiométricas únicas, permitindo capturar as atividades da Terra a partir de múltiplas perspectivas e dimensões, que em conjunto geram dados globais sem precedentes (PLANET, 2021). As imagens do *Planet* têm sido usadas na agricultura, principalmente para detectar datas de semeadura de

culturas e estimar parâmetros agronômicos, mas ainda não delineiam os limites do campo de cultivo (CHENG, Tao et al., 2020).

3.4 Processamento digital de imagens

A classificação de imagens é uma técnica fundamental para obter informações de uso e cobertura da terra a partir de imagens multiespectrais coletadas por sensoriamento remoto (ZANOTTA; ZORTEA; FERREIRA, 2018). O processamento e análise de imagens digitais avançou fundamentando-se nos conceitos de interpretação manual de imagem. Os protocolos dessa análise foram desenvolvidos primeiramente respaldados em fotografias aéreas, entretanto, são empregados atualmente também em imagens digitais de satélite (BLASCHKE et al., 2014).

A maioria dos métodos de processamento de imagem digital possuem abordagens convencionais baseadas em informações espectrais de cada *pixel* - principalmente tom ou cor, a serem representados como um número digital, de modo a definir a qual das classes temáticas disponíveis pertence (BLASCHKE et al., 2014; ZANOTTA; ZORTEA; FERREIRA, 2018).

Com a evolução e disponibilização de dados multiespectrais e de maior resolução espacial, surgiram métodos baseados na textura da imagem, informações contextuais, características morfológicas dos alvos e associação dos valores de *pixels* vizinhos, o que têm sido utilizados com o intuito de aprimorar os resultados das classificações. Essas novas abordagens são denominadas de Análises de Imagens Baseadas em Objetos (OBIA) e usualmente apresentam duas etapas: segmentação e classificação (BLASCHKE et al., 2014; ZANOTTA; ZORTEA; FERREIRA, 2018).

3.4.1 Classificação supervisionada

A intervenção do usuário inserindo amostras de coberturas terrestres de fontes conhecidas, por meio da visita à campo ou por mapas existentes, indicando os *pixels* representativos para cada uma das classes de interesse na imagem, de modo que o algoritmo de classificação extrapole essas características espectrais para outras áreas a fim de identificar áreas espectralmente semelhantes é denominada de classificação supervisionada

(ABBASZADEH; MAHDAVI; REZAI, 2019; CASTILLEJO-GONZÁLEZ et al., 2009).

As amostras de classificação supervisionadas inseridas pelo usuário são conhecidas como amostras de treinamentos, e são necessárias para construir um modelo capaz de categorizar amostras desconhecidas. Esse tipo de classificação é apropriado para discriminar características mais detalhadas da superfície (ABBASZADEH; MAHDAVI; REZAI, 2019; ĐURIĆ; PEHANI; OŠTIR, 2014).

As abordagens de classificação supervisionadas frequentemente usadas (paralelas, distância mínima e máxima probabilidade) possuem facilidade de compreensão e implementação, no entanto requerem dados de referência para ajustar os parâmetros de segmentação com a finalidade do melhor refinamento possível dos objetos alvo (ABBASZADEH; MAHDAVI; REZAI, 2019; BELGIU; DRĂGUŢ, 2014). Os classificadores de maior precisão utilizados na classificação supervisionada são: *Random Forest* (RF), *Support Vector Machine* (SVM), *Decision Tree* (DT), *Nearest Neighbour* (NN) e *Maximum Likelihood Classifier* (MLC) (HAY CHUNG; XIE; REN, 2021a; LUO; QI; et al., 2021; MA et al., 2017).

3.4.2 Processo de segmentação na identificação de alvos

A segmentação de imagens teve seu estabelecimento e difusão ao longo do final da década de 1970 e 1980, disponibilizando diversos algoritmos de segmentação. Os métodos tradicionais de segmentação são correntemente classificados em três abordagens principais: *pixel*, borda e região. Embora disponível para a comunidade da ciência da computação, a segmentação de imagens raramente era utilizada (BLASCHKE et al., 2014).

Com o advento da nova abordagem de Análise de Imagens Baseadas em Objetos (OBIA), a segmentação torna-se a base dessa perspectiva, a qual é essencialmente um processo de particionamento de uma imagem em *pixels* espacialmente homogêneos e regiões não sobrepostas que a posteriori serão identificadas como objetos (FEIZIZADEH et al., 2021). A maioria dos métodos abrangem a realização de múltiplas segmentações, sendo avaliadas de acordo com critérios concernentes aos objetivos e selecionada a segmentação mais

adequada, com o intuito de obter imagens refinadas que atendam os critérios da classificação (BELGIU; DRĂGUŢ, 2014).

A segmentação é um processo de divisão de uma imagem em regiões homogêneas baseado em vários parâmetros (pesos de banda, escala, cor, suavidade, compactação, tamanho do objeto, índice de forma, média, contraste, valores geométricos, entre outros atributos) definidos pelo operador, resultando em um conjunto de regiões formadas por *pixels* espacialmente conectados compartilhando características análogas (objetos) e mais uniformes dentro de si do que as regiões adjacentes, que posteriormente obterão um rótulo único na etapa de classificação e outros procedimentos de processamento (CASTILLEJO-GONZÁLEZ et al., 2009; ĐURIĆ; PEHANI; OŠTIR, 2014; FEIZIZADEH et al., 2021; PEÑA-BARRAGÁN et al., 2011; ZANOTTA; ZORTEA; FERREIRA, 2018). Destarte, a segmentação é considerada uma etapa de pré-processamento em uma cadeia de processamento e seus resultados raramente são previstos como produtos finais, pois não é um fim em si mesmo (BLASCHKE et al., 2014; DRĂGUŢ et al., 2014), configurando-se em uma etapa fundamental e desafiadora, dado que esta requer a intervenção do usuário para definir os parâmetros ideais de segmentação no delineamento da área de interesse, escolha essa que impactará diretamente no tamanho e tipo dos objetos da imagem (BELGIU; CSILLIK, 2018; FEIZIZADEH et al., 2021).

A qualidade da segmentação é primordial na obtenção de uma imagem classificada como precisa. Teoricamente, o resultado de um segmento deve representar um objeto de interesse, apresentando uma combinação perfeita entre os limites de segmento e o objeto. Entretanto, na prática, os resultados da segmentação são muito influenciados pela qualidade e número de faixas de imagem, como pela resolução e complexidade da cena. Ademais, grande parte dos algoritmos de segmentação necessitam do ajuste realizado pelo usuário para extrair objetos específicos de interesse, sendo frequentemente detectados segmentos errôneos bem como de omissões de segmentos genuínos, acarretando altas taxas de classificação imprecisas, demonstrando que a segmentação de imagens continua sendo uma tarefa altamente subjetiva, normalmente realizada de forma manual através de tentativa e erro (BELGIU; DRĂGUŢ, 2014; DRĂGUŢ et al., 2014; ĐURIĆ; PEHANI; OŠTIR, 2014).

O método *Multi-Resolution Segmentation Method* (MRS) e o *Hierachical Segmentation* (HSEG) são os dois algoritmos clássicos de segmentação comumente utilizados na classificação de imagem de sensoriamento remoto de alta resolução (DRĂGUŢ et al., 2014; SU; ZHANG, 2017; TETTEH; GOCHT; CONRAD, 2020).

O MRS é provavelmente o algoritmo mais popular, integrado ao sistema de *software* comercial *eCognition*® (Trimble Geospatial Imaging), considerado como um processo de fusão em pares que começa com objetos de *pixel* único bem distribuídos sobre uma imagem, em que um objeto *pixel* vizinho é encontrado de tal forma que a mudança na heterogeneidade entre eles seja mínima, considerando as características espectrais e morfológicas quantificadas como heterogeneidade de suavidade e compactação. Esse processo de fusão termina assim que o número de *pixels* em qualquer objeto exceda um valor de limiar definido pelo usuário, tornando adequada para a extração de geo-objetos artificiais porque são regularmente moldados na maioria dos cenários. Cada objeto é manuseado uma vez por ciclo de loop (DRĂGUŢ et al., 2014; SU; ZHANG, 2017; TETTEH; GOCHT; CONRAD, 2020).

Por outro lado, o HSEG baseia-se em uma abordagem clássica de fusão de regiões, permitindo que segmentos espacialmente desarticulados sejam mesclados o que, consequentemente, aumenta a precisão do processo, todavia amplia a carga computacional. O HSEG possui um limiar de escala, similar ao MRS, com o objetivo de analisar diferentes métodos de avaliação de segmentação (SU; ZHANG, 2017).

3.4.3 Análise Orientada em Geo-Objeto

A Análise de Imagem Baseada em Objetos (OBIA) ou Análise Geográfica de Imagem Baseada em Objetos (GEOBIA) é um paradigma relativamente novo empregado na interpretação de imagens de sensoriamento remoto (SU; ZHANG, 2017), incluindo teoria, métodos e ferramentas para segmentar objetos de imagem significativos e avaliar suas características através da escala, tendo como principal objetivo a geração de informações geográficas, por meio do qual novos conhecimentos espaciais ou conteúdo

geoespacial em contexto, geo-inteligência, podem ser obtidos (BLASCHKE et al., 2014; FEIZIZADEH et al., 2021).

O termo GEOBIA não se restringe apenas à comunidade de sensoriamento remoto, mas também compreende conceitos e princípios de SIG, ecologia paisagística e *GIScience*, entre outras áreas da ciência (BLASCHKE et al., 2014).

A GEOBIA tem conseguido destaque nos campos de sensoriamento remoto e ciência da informação geográfica (GIScience) na última década, especialmente para o processamento de imagens de alta resolução espacial, tornando-se aprovada como um método eficiente para extrair informações detalhadas de imagens de satélite. A OBIA frequentemente usa um algoritmo de segmentação de várias resoluções que agrupa células de grade individuais em objetos de imagem, de modo que são classificados usando regras de classificação (ANDERS; SEIJMONSBERGEN; BOUTEN, 2011; BELGIU; DRĂGUŢ, 2014; DRĂGUŢ et al., 2014).

A Análise Geográfica de Imagem Baseada em Objetos constitui-se basicamente em duas etapas principais que são a segmentação e a classificação desses segmentos de imagens resultantes (ROSSI et al., 2020b; SILVA JUNIOR et al., 2019a). A segmentação é responsável por particionar a imagem de entrada em diversos segmentos homogêneos (ou regiões), considerada um pré-requisito crucial, pois sua qualidade afeta em grande parte o desempenho final do reconhecimento dos objetos de imagem, denominados como geo-objetos. Sucessiva à etapa de segmentação, realiza-se a classificação dos geo-objetos mediante diversas características baseadas em suas informações espectrais, espaciais e contextuais (ĐURIĆ; PEHANI; OŠTIR, 2014; SU; ZHANG, 2017), sendo atribuídas às classes de destino usando estratégias de classificação supervisionadas ou não supervisionadas.

Essa abordagem tem potencial utilização para classificação de lavouras, detecção de estruturas urbanas, e reconhecimento de objetos costeiros e oceânicos, entre vários outros usos (BELGIU; CSILLIK, 2018; SU; ZHANG, 2017).

Para minimizar os problemas decorrentes da heterogeneidade dos *pixels,* como a produção de ruídos denominados "sal e pimenta" e a variabilidade

da cultura no campo, as técnicas baseadas em objetos têm sido cada vez mais implementadas na análise de imagens. Destarte, a classificação baseada em objetos é altamente recomendada para aplicações que utilizam imagens de satélite de média a alta resolução para mapear os cultivos agrícolas (LUO; QI; et al., 2021; PEÑA-BARRAGÁN et al., 2011; ZANOTTA; ZORTEA; FERREIRA, 2018).

Com o objetivo de aproveitar profundamente a metodologia da GEOBIA, as particularidades de campo que caracterizam cada cultura precisam ser identificadas e avaliadas de modo a serem utilizadas no procedimento de classificação baseado em objetos (PEÑA-BARRAGÁN et al., 2011).

3.4.3.1 Cor, textura, tamanho e forma

Subsequente ao processo de segmentação, as regiões homogêneas ou objetos de imagens podem ser classificados em diversos parâmetros, um destes é a cor, que depende da qualidade da percepção espectral bem como de fatores ambientais. Os índices de vegetação também são utilizados na segmentação de imagens, orientada para detectar linhas de culturas em imagens de campo (ZHENG et al., 2017).

A análise da vegetação por cores é provavelmente o método mais eficiente para a classificação das culturas. A cor é criada a partir da soma estimada dos desvios padrão de cada banda em uma região específica, em qual cada peso da banda é definido pelo usuário (ROSSI et al., 2020c). As características de cores (espectrais) comumente usadas são: Desvio médio e padrão de todas as bandas, Brilho, *Normalized Difference Vegetation Index* (NDVI), *Normalized Difference Water Index* (NDWI), *Enhanced Vegetation Index* (EVI), *Land Surface Water Index* (LSWI) (WANG, Xiaona et al., 2021).

A textura, outro parâmetro, refere-se a frequências particulares de mudança de tons e seus arranjos espaciais resultantes. Uma forma robusta de textura de imagem é construir sobre a interação espacial de objetos de imagem vizinhos (BLASCHKE et al., 2014). Para a obtenção da característica textural podem ser extraídas das imagens: momento angular, correlação, contraste, destaque do cluster, sombra de cluster, variação de densidade, probabilidade máxima, variância de diferença, entropia, entropia de diferença, entropia de

soma, homogeneidade, soma de quadrados, momentos de diferença inversa, soma média, variância de soma, entre outros atributos (RAHMAN et al., 2020).

O parâmetro tamanho de um objeto de imagem é determinado pela escala que define os limites das características, e são utilizados vários atributos para alcançar a escala mais adequada de acordo com características espaciais e valores derivados das características interessadas (FEIZIZADEH et al., 2021).

A forma refere-se à conformação geral ou contorno de objetos individuais, indicando o peso para inserir na condição de objeto durante o processo de segmentação em comparação com informações de cor (espectral) (BLASCHKE et al., 2014; TETTEH; GOCHT; CONRAD, 2020). As características de forma podem ser baseadas na região ou baseadas em limites, estas como perímetro e excentricidade, aquelas como área e compactação (RAHMAN et al., 2020). As características de formas mais utilizadas são: comprimento/largura, índice de forma, área (*pixels*), índice de borda, arredondamento, ajuste retangular (WANG, XIAONA et al., 2021).

3.4.4 Classificador *Random Forest* (RF)

O classificador *Random Forest* (RF) é uma árvore de classificação e regressão, denominada *Classification and Regression Tree* (CART), considerado um algoritmo de aprendizado de máquina popular, bastante adotado na classificação de sensoriamento remoto (LUO; QI; et al., 2021; PAL, 2005a), que atua empregando a técnica de amostragem *bootstrap* para extrair aleatoriamente amostras do conjunto de dados originais para gerar um novo conjunto de treinamento.

Além disso, é um classificador não paramétrico supervisionado estabelecido que pode acomodar relações não lineares entre variáveis e não faz suposições sobre suas distribuições estatísticas, apresentando-se como um conhecido método de aprendizagem de conjunto que combina árvores CART binárias K, somadas a agregação de *bootstrap* (ensacamento) para formar um novo conjunto de árvores, procurando subespaços aleatórios a partir das características dadas e a melhor divisão dos nós, minimizando a correlação entre elementos (PELLETIER et al., 2016; WESSELS et al., 2016; XIONG et al., 2017).

Durante a fase de decisão, cada árvore (aprendiz individual) classifica os dados do recurso de entrada, para que em seguida produza a etiqueta de classe que recebeu a maioria dos votos (PELLETIER et al., 2016; WESSELS et al., 2016; XIONG et al., 2017). Assim, esse classificador é definido como um preditor constituído por uma coleção de árvores de regressão de base aleatória $\{r_n(x,\theta_n,D_n),m\geq 1$, que são integradas para criar a estimativa de regressão agregada como $\bar{r}n(X,Dn)=E\theta[r_n(X,\theta,Dn)]$, onde Eθ define a expectativa em relação aos parâmetros aleatórios, condicionalmente em X e no conjunto de dados Dn, utilizando o Índice de Gini (EQUAÇÃO 1) como medida de seleção de atributos para medir a impureza de um atributo em relação às classes (JAMALI, 2019; PAL, 2005b).

$$\sum\sum_{j\neq i}(f(C_i,T)\,/\left|T\right|\left|\left(C_j,T()|T|\right)\right| \quad (1)$$

Onde:

f (C_i , T)/ |T| é a probabilidade de que o caso selecionado pertença à classe C_i .

4. METODOLOGIA E DELINEAMENTO DA PESQUISA

4.1. Área de estudo

A área de estudo compreende o município de Canarana, localizado na mesorregião Nordeste do estado de Mato Grosso, situado entre as coordenadas geográficas 12º36’17” a 13º47’12’’ S e 51º22’32’’ a 53º06’12’’ W (FIGURA 1), possui área territorial de 10.855,181km² e população estimada em 21.842 habitantes. A altitude média da localidade é de 390 metros, caracterizada pelo clima tropical úmido (classificação climática de Köppen-Geiger: Aw), apresentando duas estações definidas: seca (de maio a setembro) e chuvosa (de outubro a abril) e sua temperatura média é de 25°C (ALVES; REZENDE; SPOSITO, 2009; IBGE, 2020).

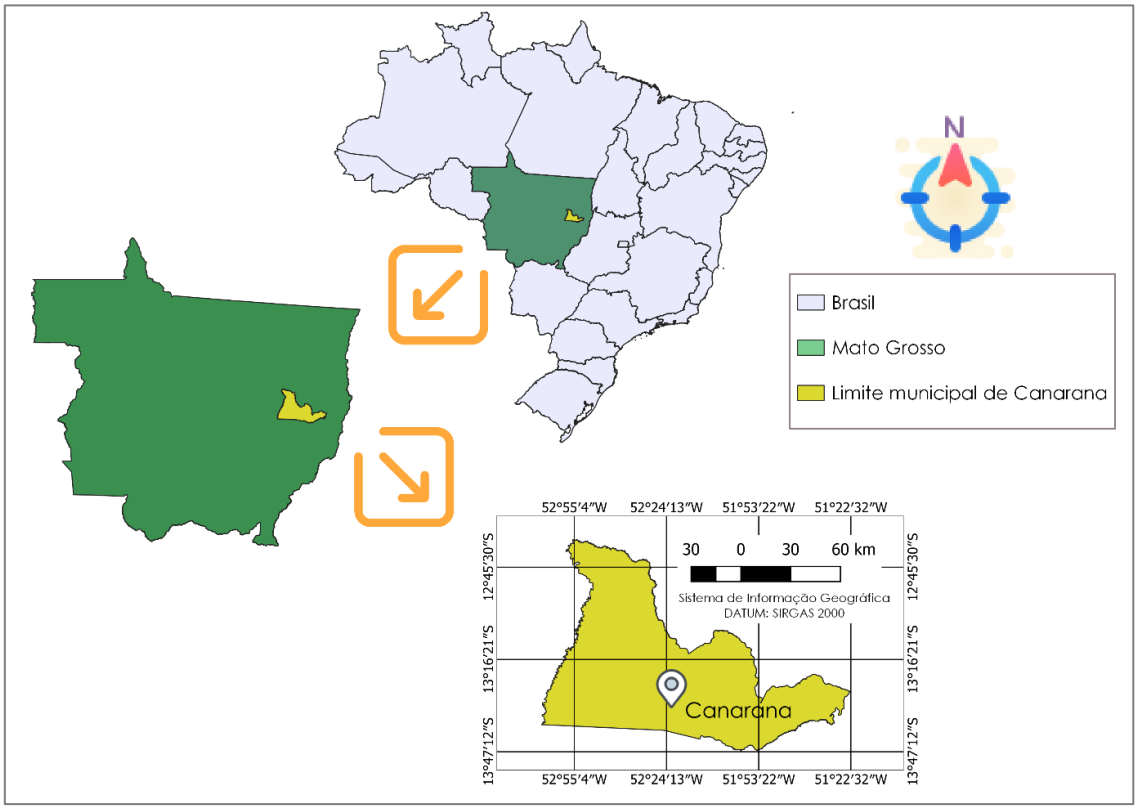

FIGURA 1: Mapa de localização do município de Canarana. Fonte: IBGE. Elaboração: o autor

O município de Canarana se situava na área de domínio da Superintendência do Desenvolvimento da Amazônia (SUDAM) e teve sua origem em 1972, por instrumento de um projeto da primeira cooperativa colonizadora do país, a Cooperativa Colonizadora 31 de Março Ltda – COOPERCOL. O propósito

do projeto era atrair para a região empresários rurais (grandes, médios e pequenos), multinacionais e produtores familiares. Atualmente, as principais atividades econômicas do município são a pecuária, agricultura (arroz, milho, gergelim e soja) e agroindústria. Seu território é marcado pela transição dos biomas Amazônia e Cerrado (FIGURA 2), correspondendo a 34,51% e 65,49% da área municipal, respectivamente (ALVES; REZENDE; SPOSITO, 2009; FERREIRA et al., 2001; IBGE, 2020; MAPBIOMAS, 2021), com uma aptidão agrícola predominante de boa e regular para implantação de lavouras (FIGURA 3)

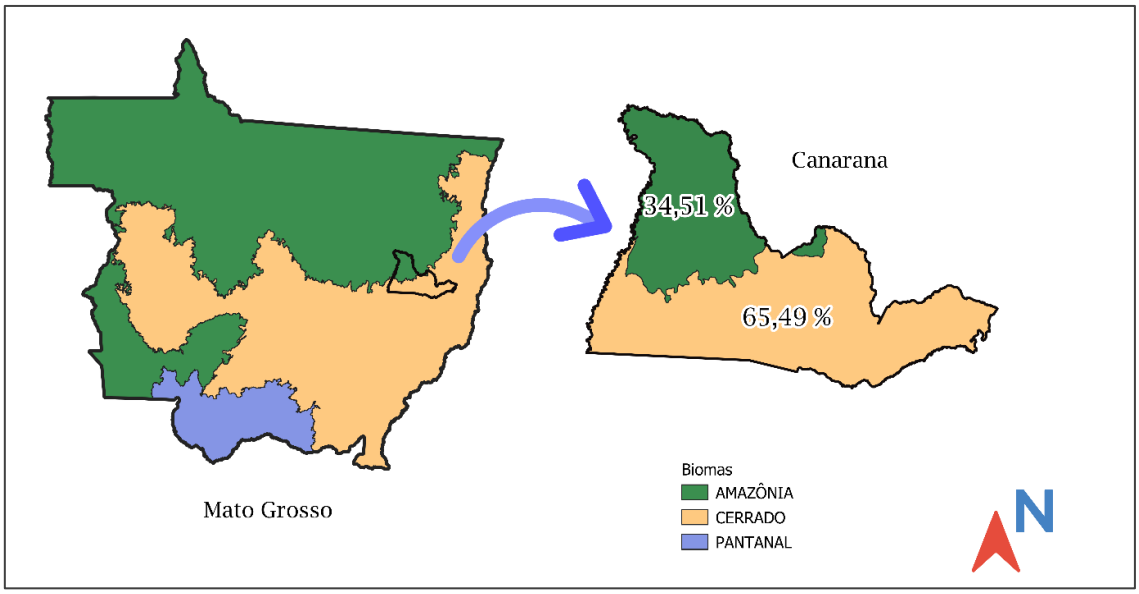

FIGURA 2: Biomas em Mato Grosso e Canarana. Fonte: IBGE. Elaboração: o autor

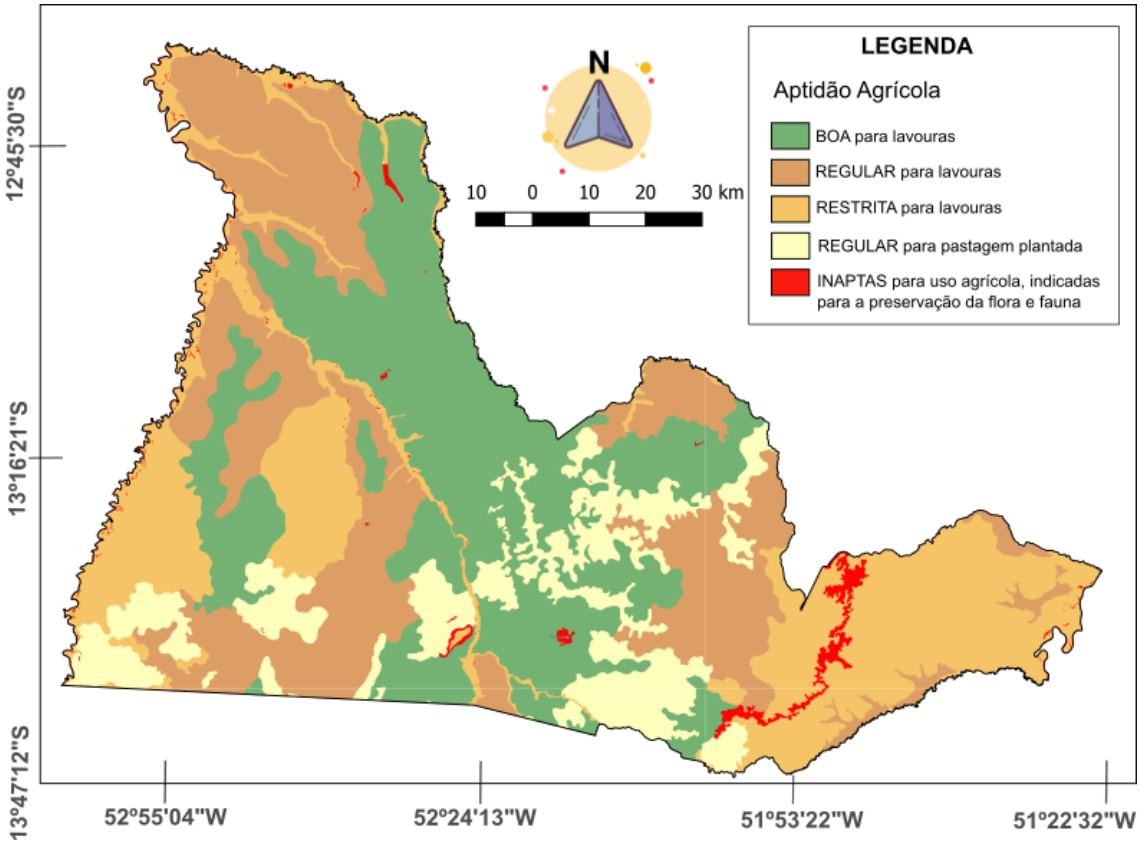

FIGURA 3: Mapa de Aptidão Agrícola para o município de Canarana. Fonte: PRONASOLOS. Elaboração: o autor

4.2. Pré-processamento

A princípio, obteve-se a base cartográfica do IBGE do limite municipal de Canarana, e posteriormente realizado o *upload* ao *Assets* do GEE. Todas as imagens empregadas neste trabalho derivaram da plataforma do GEE, em especial às *PlanetScope* NICFI, dado que a adição do conjunto desses dados de alta resolução, 4,77 m, ao catálogo de dados públicos do GEE representa um avanço primoroso no uso de imagens de alta resolução espacial abertamente disponíveis para a classificação da superfície terrestre, e tal feito é fruto da recente parceria entre o *Google* e a *International Climate and Forest Initiative* (NICFI) da Noruega (O'SHEA, 2021; SULLIVAN, 2021).

Esses conjuntos de dados fornecem séries temporais mensais, a partir de 2020, com quatro bandas (RGB + NIR) e cobertura de 94 países nos trópicos globais (FIGURA 4), inclusive de grande parte do território brasileiro (O'SHEA, 2021; SULLIVAN, 2021). A disponibilidade de dados do *PlanetScope*

dentro do GEE de forma gratuita é um passo importante para mapear e monitorar a dinâmica do uso e ocupação do solo em alta resolução em paisagens tropicais (VIZZARI, 2022b). Diante disso, as imagens dos satélites (Terra/Aqua (MODIS), *Landsat-8* (OLI), *Sentinel-2A-B* (MSI) e *Planet* NIFCI) foram obtidas e processadas no GEE, semelhantemente realizado por AMANI et al., 2020; ANEECE; THENKABAIL, 2018; BELCORE; PIRAS; WOZNIAK, 2020; HAY CHUNG; XIE; REN, 2021b; LUO et al., 2021; MANANZE; PÔÇAS; CUNHA, 2020; PRATICÒ et al., 2021; QU et al., 2021.

Aplicou-se um filtro, nas imagens adquiridas, com data entre 01/04/2022 e 31/05/2022, uma vez que nesse período se concentra o estádio de maior vigor vegetativo da cultura do milho 2ª safra, com filtragem de nuvens de até 0,35%. De forma a obter uma única imagem para representar o período coletado utilizou-se a mediana desse intervalo (ROSSI et al., 2020a; SAAD EL IMANNI et al., 2022; SCHULTZ et al., 2019b, a; SEYDI et al., 2021; STROMANN et al., 2019; TASSI et al., 2021a, b; TASSI; VIZZARI, 2020; VIZZARI, 2022b, a; XIONG et al., 2017; YU et al., 2020).

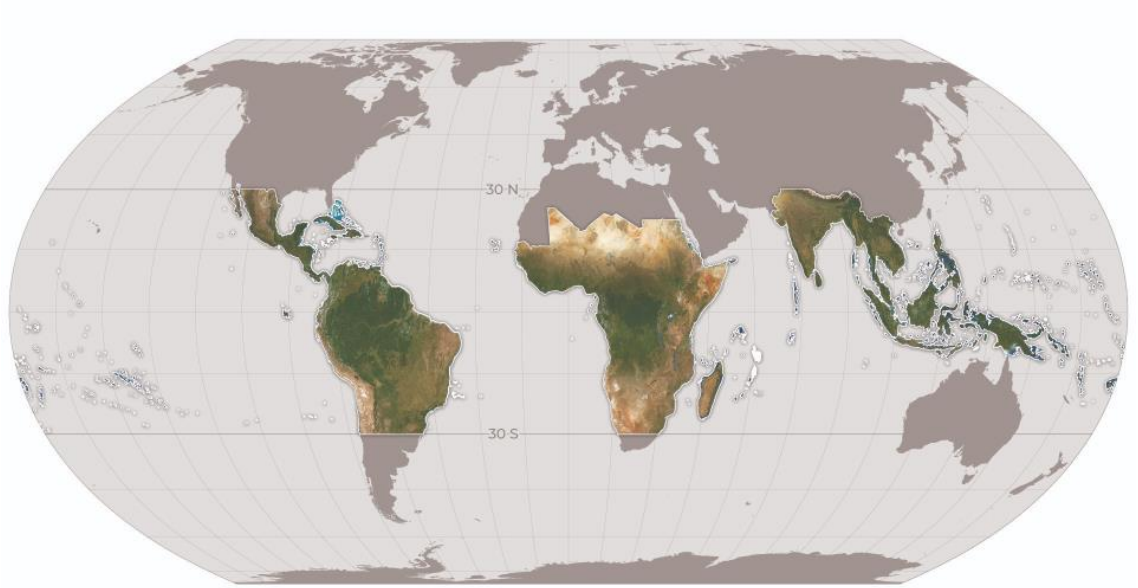

FIGURA 4: Cobertura pantropical do programa NICFI. Fonte: Planet NICFI

De modo a reduzir os efeitos da irregularidade do terreno, antes do cálculo dos índices espectrais subsequentes e classificação de imagem, fez-se necessário realizar a correção topográfica (RICHTER; KELLENBERGER;

KAUFMANN, 2009; TASSI et al., 2021b). A referida correção é baseada em um método semi-empírico que leva em consideração a topografia da área e o ângulo solar (zênite e azimute), denominado método de correção *Solar Canopy Sensor +C* (SCSc) (BELCORE; PIRAS; WOZNIAK, 2020; SHEPHERD; DYMOND, 2003; TASSI et al., 2021b), implementado em um script no GEE (BURNS; MACANDER, 2018). Em conjunto com este método empregou-se o Modelo Digital de Elevação (MDE) do sensor *PALSAR* do satélite *ALOS* cuja resolução espacial é de 12,5 m (NGULA NIIPELE; CHEN, 2019).

Quanto à aplicação dos índices de vegetação, foi utilizado o NDVI (EQUAÇÃO 2), que permite gerar uma imagem exibindo o tom verde (biomassa relativa), aproveitando o contraste das características das absorções de pigmento de clorofila na faixa vermelha e a alta reflexividade dos materiais vegetais na banda do Infravermelho Próximo (NIR) (SILVA JUNIOR et al., 2017).

Também foi aplicado o *Enhanced Vegetation Index* (EVI) (EQUAÇÃO 3), semelhante ao NDVI, esse porém, desenvolvido para atenuar os efeitos do solo (ajustado pelo *Soil Adjusted Vegetation Index* - SAVI) e da atmosfera (ajustado pelo ARVI - *Atmospherically Resistant Vegetation Index*) no mapeamento de vegetação, de forma a ser menos sensível ao ruído de fundo e ao atmosférico, além de não se tornar tão saturado quanto o NDVI ao visualizar áreas com vegetação de denso verde (SILVA JUNIOR et al., 2017).

O emprego do Índice de Vegetação Perpendicular (PVI) (EQUAÇÃO 4) permite anular a reflectância do solo, visto que, no estádio de emergência da cultura parte dessa reflectância registrada pelo sensor refere-se ao solo exposto. O Índice de Melhoramento de Cultura Perpendicular (PCEI) (EQUAÇÃO 5) foi utilizado para discriminar o período de mínimo e máximo desenvolvimento da cultura (SILVA JUNIOR et al., 2017).

$$NDVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V} \quad (2)$$

$$EVI = g \times \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + (C_1 \times \rho_V) - (C_2 \times \rho_A) + 1} \quad (3)$$

$$PVI = \frac{\rho_{IVP} - (a \times \rho_V \ ) - b}{\sqrt{1 + a^2}} \quad (4)$$

$$PCEI = g \times \frac{(MaxPVI+S) - (MinPVI+S)}{(MaxPVI+S) + (MinPVI+S)} \quad (5)$$

Onde:

ρ_{IVP} - Reflectância na faixa espectral do infravermelho próximo;

ρ_V - Reflectância na faixa espectral do vermelho;

ρ_A - Reflectância na faixa espectral do azul;

g - Fator de ganho (10^2);

c1 - Coeficiente de correção dos efeitos atmosféricos para o vermelho (6,0);

c2 - Coeficiente de correção dos efeitos atmosféricos para o azul (7,5);

a - Declividade da linha do solo (1,17);

b - Intercepto da linha do solo (3,37);

MaxEVI - Valor máximo de EVI observado no período de máximo desenvolvimento da cultura;

MaxPVI - Valor máximo de PVI observado no período de máximo desenvolvimento da cultura da soja;

MinEVI - Valor mínimo de EVI observado no período de pré-plantio e/ou emergência;

MinPVI - valor mínimo de PVI observado no período de pré-plantio e/ou emergência;

S - Coeficiente de realce (10^2).

4.3. Segmentação e classificação

Com finalidade de classificação da área de estudo foram usadas as seguintes imagens: (a)*Terra/Aqua* (MODIS); (b)*Landsat-8* (OLI), (c)*Sentinel-2A-B* e (d)*PlanetScope*. Recorreu-se à extração de recursos texturais através da *Gray Level Co-occurrence* (GLCM), a fim de alcançar melhores resultados na etapa de segmentação. (EQUAÇÕES 6, 7, 8, 9 e 10), que calcula as estatísticas de segunda ordem das características da textura a partir da distribuição das combinações observadas de intensidade em posições especificadas em relação umas às outras na mesma imagem (REGE; WARNEKAR; LEE, 2022; SILVA JUNIOR et al., 2019b). Esse algoritmo é amplamente utilizado no GEE e requer

uma imagem de nível cinza de 8 *bits* gerada através da combinação linear de bandas NIR, Vermelho e Verde da imagem original, e como resultado fornece dezoito índices texturais diferentes (TASSI et al., 2021b; TASSI; VIZZARI, 2020). Desse total, foram selecionados três modelos de textura: *Inverse Difference Moment* (IDM); *Sum of Entropy* (SENT) e *Dissimilarity* (DISS) (SILVA JUNIOR, 2014).

$$mean = \frac{1}{\sharp P_{\mathrm{Obj}}} \sum_{(x,y)\in P_{\mathrm{Obj}}} C_k(x,y) \tag{6}$$

$$Standard\ deviation = \sqrt{\frac{1}{\sharp P_{\mathrm{Obj}}} \sum_{(x,y)\in P_{\mathrm{Obj}}} * \left(c_k(x,y) - \frac{1}{\sharp P_{\mathrm{Obj}}} \sum_{(x,y)\in P_{\mathrm{Obj}}} c_k(x,y) \right)} \tag{7}$$

$$GLCM\ homogeneity = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2} \tag{8}$$

$$GLCM\ dissimilarity = \sum_{i,j=0}^{N-1} P_{ij}|i-j| \tag{9}$$

$$GLCM\ entropy = \sum_{i,j=0}^{N-1} P_{ij}(-\ln\ P_{ij}) \tag{10}$$

Onde:

P_{Obj} - $\{(\mathrm{x},\mathrm{y}):(\mathrm{x},\mathrm{y}) \in P_{\mathrm{Obj}}\}$ conjunto de pixels de um objeto de imagem;

$\sharp P_{\mathrm{Obj}}$- número total de pixels contidos no P_{Obj};

$c_k(\mathrm{x},\mathrm{y})$ - valor da camada de imagem em pixel (x,y), onde (x,y) são coordenadas de pixel;

i - número da linha da matriz de coocorrência;

j - número da coluna da matriz de coocorrência;

$P_{i,j}$- o normalizado na célula i, j: $P_{i,j} = (V_{i,j} / \sum_{i,j=0}^{N-1} V_{i,j})$;

$V_{i,j}$- o valor na célula i, j da matriz de coocorrência;

e N - o número de filas ou colunas da matriz de coocorrência.

Após o procedimento aludido, efetuou-se uma Análise de Componentes Principais (PCA) com vista a reduzir a dimensionalidade dos dados, neste caso, 16 bandas (sendo bandas originais, índices de vegetação e recursos texturais), para maximizar a quantidade de informações originais no menor número de componentes principais (ESTORNELL et al., 2013; LIMA et al., 2022; TASSI et al., 2021b).

Esse processo reduz significativamente a carga computacional para extração de recursos, transformando um conjunto de variáveis correlacionadas (bandas originais) em variáveis distintas não correlacionadas (componentes principais) que contêm o máximo de informações primárias, acelerando significativamente o processo de classificação de máxima verossimilhança (JIA; RICHARDS, 1999), além disso, esses cálculos têm sido amplamente aplicados em sensoriamento remoto para classificar o uso e ocupação do solo e suas alterações (ESTORNELL et al., 2013; NRCAN, 2022).

Em seguida, as imagens passaram pela etapa de segmentação, qualificada pela aplicação do algoritmo de *Simple Non-Iterative Clustering* (SNIC) (ACHANTA; SUSSTRUNK, 2017), disponível e extensamente usado no GEE, para agrupar *pixels* semelhantes em objetos de imagem, possuindo informações espectrais e texturais que serão empregadas na etapa de classificação. O SNIC é uma versão melhorada do algoritmo de segmentação *Simple Linear Iterative Clustering* (SLIC) que se beneficia de um procedimento não iterativo e impõe a regra de conectividade desde o estágio inicial (TASSI et al., 2021b; TASSI; VIZZARI, 2020)

A princípio, o SNIC inicia os centroides dos *pixels* na grade regular da imagem, sendo a distância de *pixels* no espaço dimensional de cores e coordenadas espaciais usada para determinar a dependência de cada *pixel* em relação ao centroide. Finalmente, as distâncias espaciais e coloridas integradas resultam em polígonos eficientes, compactos e quase uniformes, proporcionando a identificação dos objetos (*clusters*) de acordo com os parâmetros de entrada, gerando um *raster* de várias bandas, incluindo *clusters*

e camadas adicionais contendo valores médios dos recursos de entrada (AMANI et al., 2020; LUO; QI; et al., 2021).

Os principais parâmetros do algoritmo SNIC são: imagem, tamanho, compactação, conectividade, tamanho da vizinhança e *seeds* (AMANI et al., 2020; LUO; QI; et al., 2021).

Na etapa de classificação, consecutiva à segmentação, aplicou-se o classificador *Random Forest* (RF) devido a sua robustez e comprovada superioridade a outros algoritmos na precisão de classificação como também por sua facilidade no uso na plataforma de nuvem GEE (AMANI et al., 2020; CHENG, Xinmeng et al., 2022; E. D. CHAVES; C. A. PICOLI; D. SANCHES, 2020; LUO; QI; et al., 2021; TASSI et al., 2021b; TASSI; VIZZARI, 2020), além de fornecer uma probabilidade reduzida de variáveis explicativas aos dados de treinamento, encaixando-as perfeitamente, independentemente do grande número de árvores de decisão, em que cada elemento usa um subconjunto aleatório dos dados de treinamento e um número limitado de variáveis preditoras selecionadas aleatoriamente (WESSELS et al., 2016).

4.4. Validação da classificação

Foram coletados 2.200 (dois mil e duzentos) pontos aleatórios a campo em coordenadas geográficas (latitude e longitude) da cultura de milho e outros usos do solo (água, algodão, área de expansão agrícola, área em recuperação, área urbana, cerrado, crotalária, feijão, floresta, gergelim, milheto, milho safrinha, pastagem, pastagem degradada, pousio, solo exposto, sorgo), para o treinamento e validação do classificador RF (FIGURA 5). Utilizou o aplicativo *Locus Map* instalado em um *Tablet Android* para a coleta desses pontos com precisão média de 5 m. Para cada classe de amostras utilizou 70% dos pontos na fase de treinamento e 30% na fase de validação, selecionados aleatoriamente (LUO; QI; et al., 2021; TASSI et al., 2021b; TASSI; VIZZARI, 2020).

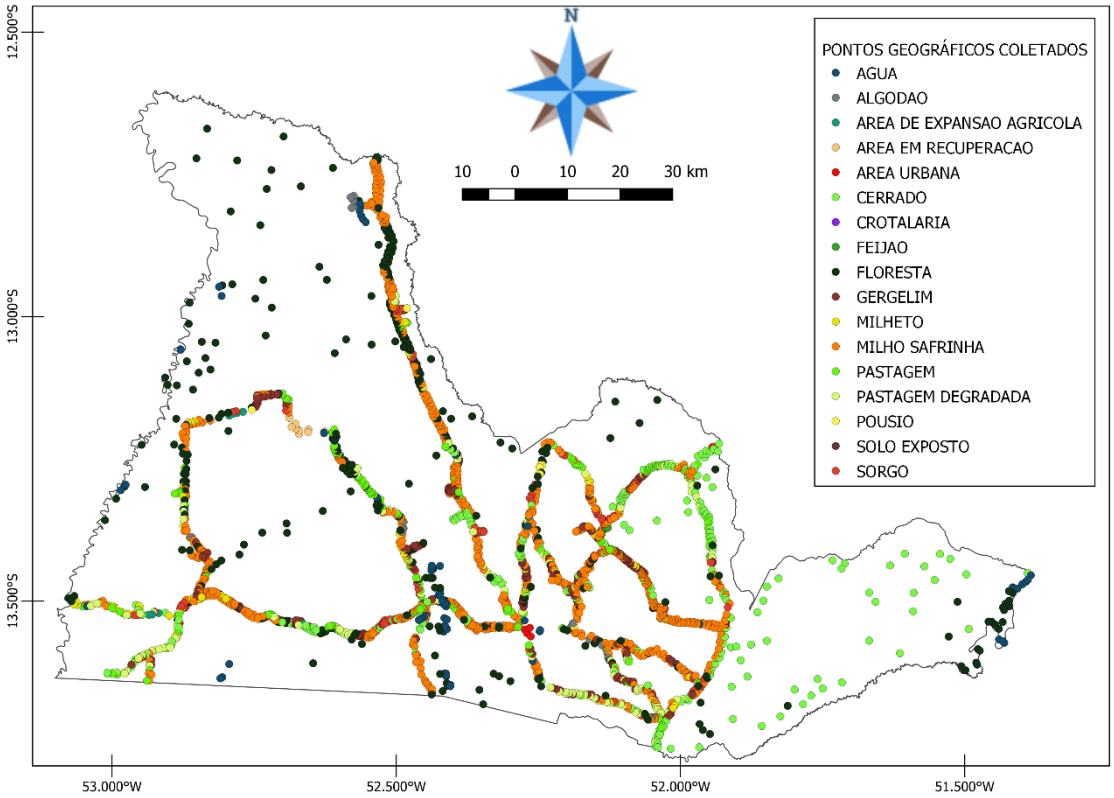

FIGURA 5: Pontos geográficos de diversos usos do solo em Canarana-MT. Fonte: o autor

Após o processamento e classificação das imagens e a confecção dos mapas temáticos das áreas de milho, procedeu-se a análise da matriz de confusão numérica implementada no GEE, que é responsável por determinar a exatidão do método ao comparar a porcentagem de objetos classificados por classe com a classe real verificada a campo, indicando a posteriori a avaliação correta e os erros entre os estratos estudados. A matriz de confusão fornece a Acurácia Global (AG) (EQUAÇÃO 11) da classificação; a Acurácia do Produtor (AP) (EQUAÇÃO 12) ou erro de omissão que, por sua vez, indica a probabilidade do resultado classificado na imagem realmente represente essa categoria na realidade; e a Acurácia do Usuário/Consumidor (AC) (EQUAÇÃO 13) ou erro de comissão, que indica o percentual de acerto de um polígono ou um *pixel* verdadeiro (referência) de ter sido corretamente classificado (AMANI et al., 2020; CASTILLEJO-GONZÁLEZ et al., 2009; LUO; QI; et al., 2021; TASSI et al., 2021b; TASSI; VIZZARI, 2020; XU, 2021).

Além dessas análises foram empregadas as métricas do índice Kappa (EQUAÇÃO 14) a fim de avaliar a confiabilidade e a precisão dos dados

classificados (SILVA JUNIOR et al., 2014). A FIGURA 6 demonstra a diagramação de toda a metodologia adotada nesse estudo.

$$\mathrm{AG}\ (\%) = \frac{\sum_{i=1}^{n} Pii}{N} \times 100 \quad (11)$$

$$\mathrm{AP}\ (\%) = \frac{P_{ii}}{P_{+i}} \times 100 \quad (12)$$

$$\mathrm{AU}\ (\%) = \frac{P_{ii}}{P_{i+}} \times 100 \quad (13)$$

$$\mathrm{kappa}\ (\%) = \frac{N \times \sum_{i=1}^{n} Pii - \sum_{i=1}^{n} (P_{i+} \times P_{+i})}{N^2 - \sum_{i=1}^{n} (P_{i+} \times P_{+i})} \times 100 \quad (14)$$

Onde:

n: número total de colunas da matriz de confusão, isto é, o número total de categorias;

P_{ii}: número de classificações corretas da amostra do tipo de cultura superior na linha *i* e coluna *i* da matriz de confusão;

P_{i+}: número total de amostras do tipo de cultura na linha i;

P_{+i}: número total de amostras do tipo de cultura na coluna i;

N: número total de amostras utilizadas para verificação.

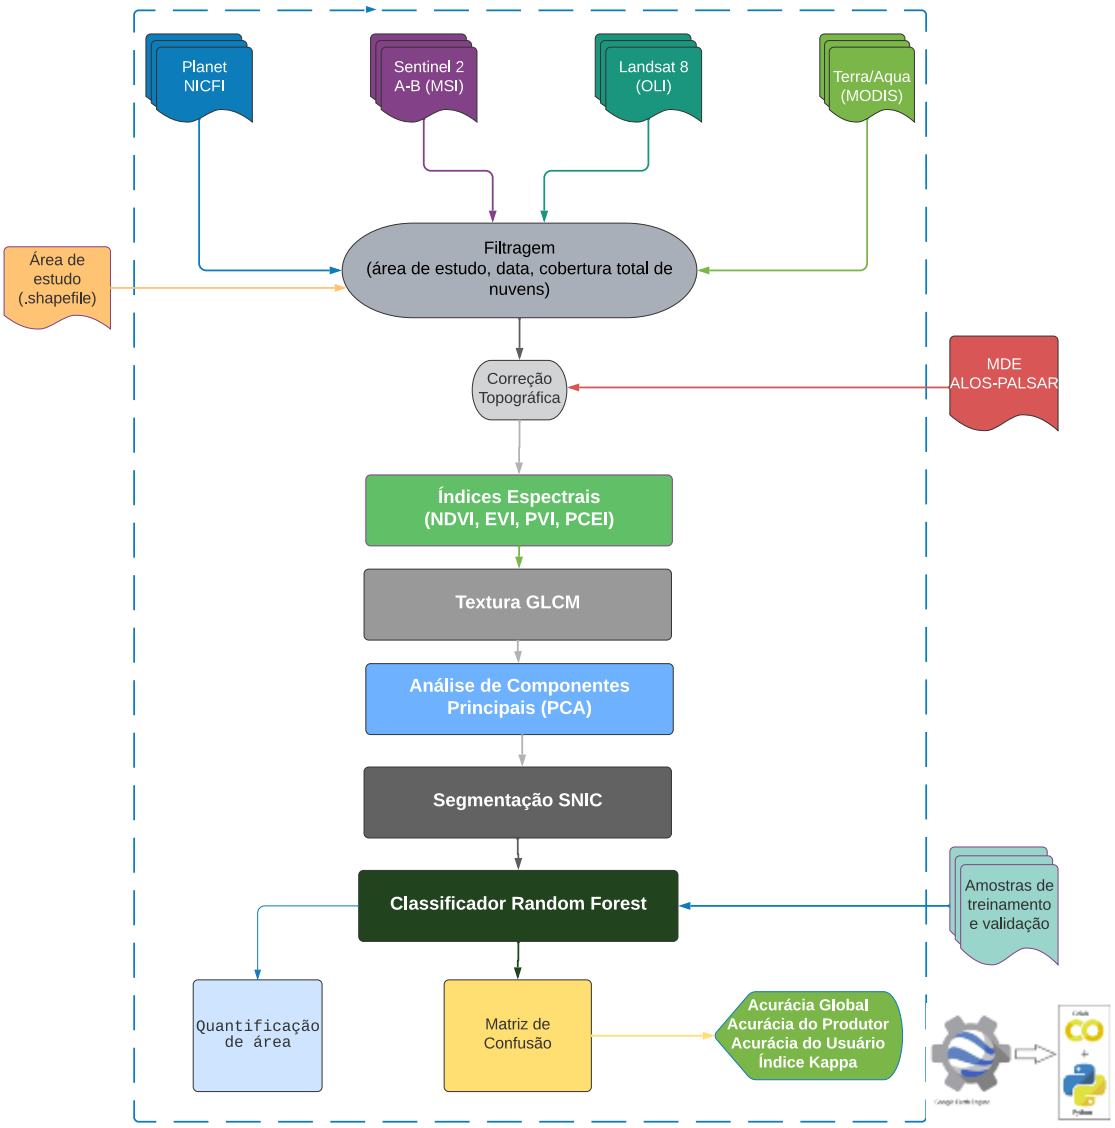

FIGURA 6: Fluxograma da metodologia da classificação orientada a objeto no GEE. Fonte: o autor

Como mencionado anteriormente, na coleta de pontos a campo foi utilizado o aplicativo *Locus Map*, para as edições de arquivos externos ao GEE (shape do município, pontos coletados, MDE, entre outros) fez-se uso do QGIS 3.22, e para as edições e diagramação das imagens utilizou-se o *software Inkscape 1.2* Para acesso ao *Google Earth Engine*, foi aplicada a linguagem de programação *Python* por meio de uma *Application Programming Interface* (API) pelo *Google Colab*. É valido salientar que as ferramentas empregadas no presente trabalho se fundamentaram integralmente em *softwares* livres (*Open source*) ou gratuitos.

.

5. RESULTADOS E DISCUSSÃO

Por intermédio do MDE *Alos Palsar*, derivaram-se duas classes de uso do solo com limiar de 12% de declividade (FIGURA 7), baseadas no fator mecanização como um dos atributos a serem observados na aptidão agrícola, considerando que algumas máquinas, principalmente colhedoras, disponíveis no mercado são adaptadas para declividade de até 12% (MANZATTO et al., 2009; SILVA, 2016; GARCIA et al., 2020). Nesse sentido, obteve-se um total de 10.465,36 km² de áreas até 12% de declividade, correspondendo a 96,55% da área total do município.

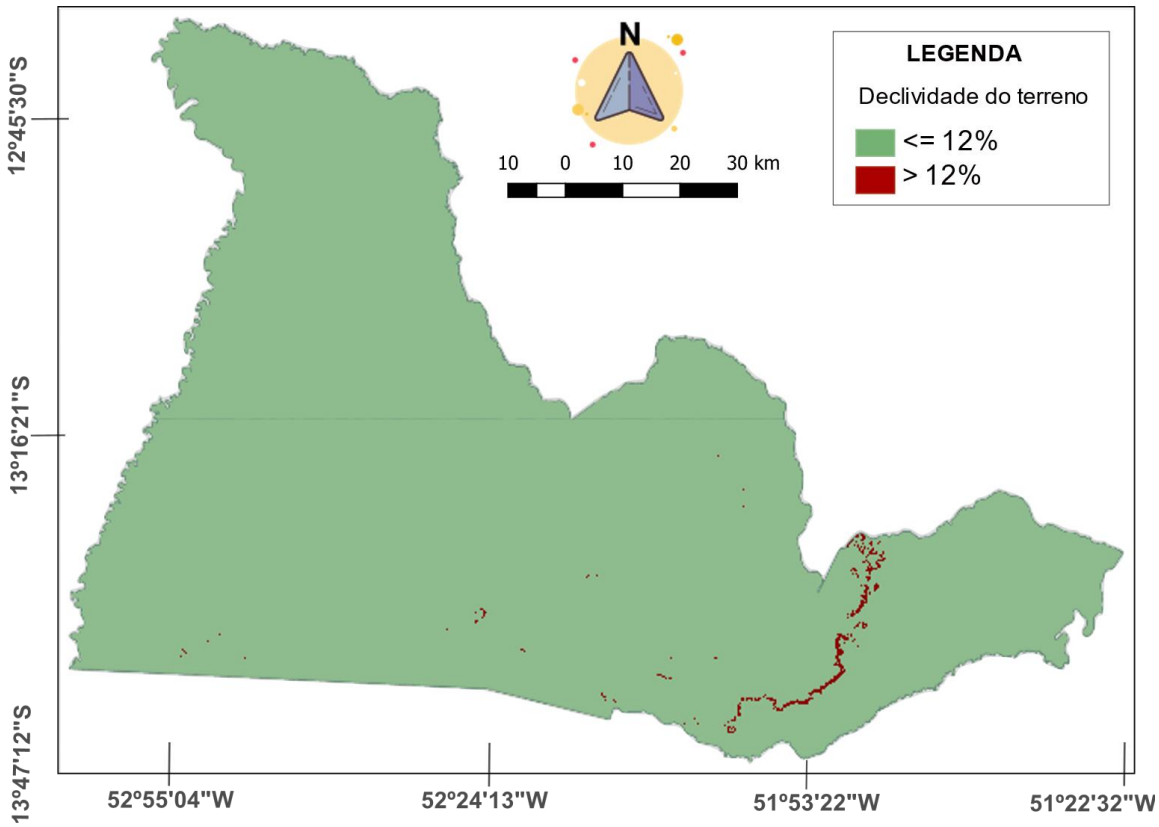

FIGURA 7: Declividade do terreno em Canarana, utilizando 12% de declividade como limite entre áreas mecanicamente agricultáveis e não agricultáveis. Fonte: o autor

Com os dados de reflectância das bandas do Vermelho(R), Verde (G), Azul (B) e NIR dos quatro sensores (FIGURA 8), bem como os níveis de cinza das imagens, a declividade do terreno e os índices de vegetação (FIGURAS 9, 10, 11 e 12), obtiveram-se 16 bandas para a avaliação da classificação da superfície terrestre na área de interesse. Nessas *features* foi empregado o

mecanismo estatístico PCA, propondo-se reduzir a quantidade de bandas para o processamento, técnica satisfatória para melhorar resultados de classificação supervisionada. No estudo foram aplicadas as três primeiras componentes (PC1, PC2 e PC3), que corresponderam a quase 100% da variância da imagem original de 16 bandas (TABELA 1).

Os resultados corroboram com os trabalhos desenvolvidos por ANEECE; THENKABAIL (2018), ESTORNELL et al. (2013) e TASSI; VIZZARI (2020) que obtiveram mais de 90% da informação das bandas originais nos primeiros três componentes principais. Esse procedimento envia um sinal mais forte para o classificador e melhora sua precisão, permitindo que ele distinga melhor as diferentes classes (FIGURA 13).

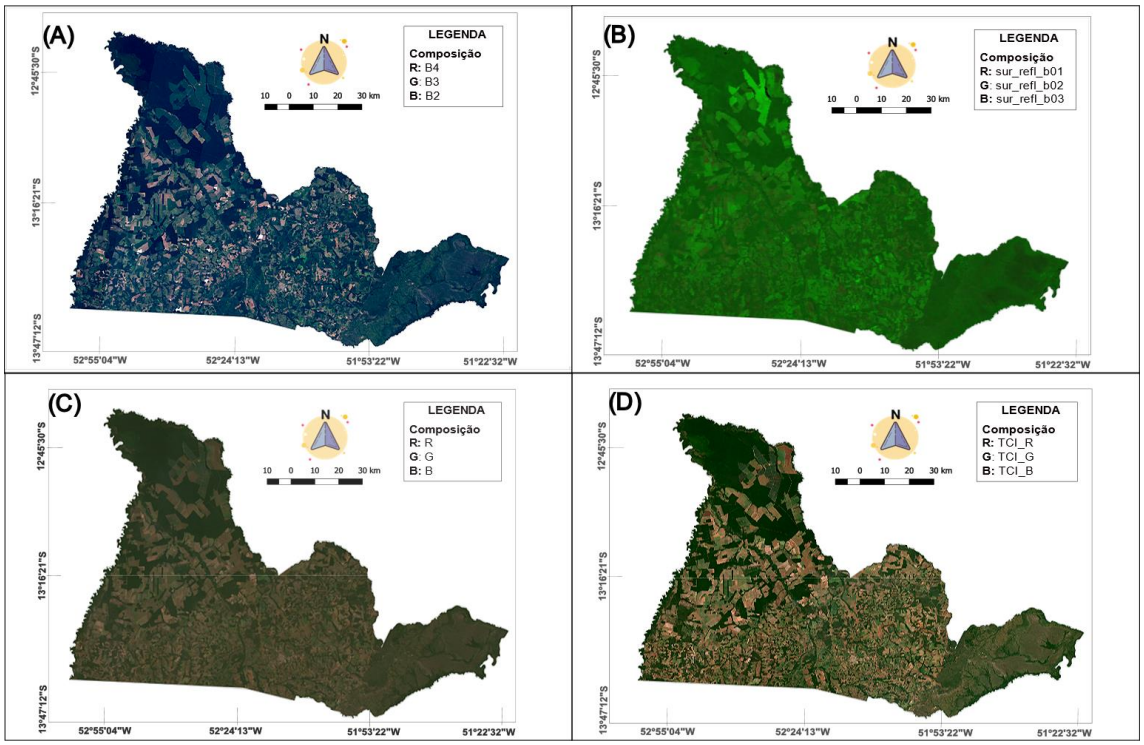

FIGURA 8: Mosaicos das imagens utilizadas na classificação de uso e ocupação do solo em Canarana-MT: (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Imagens *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

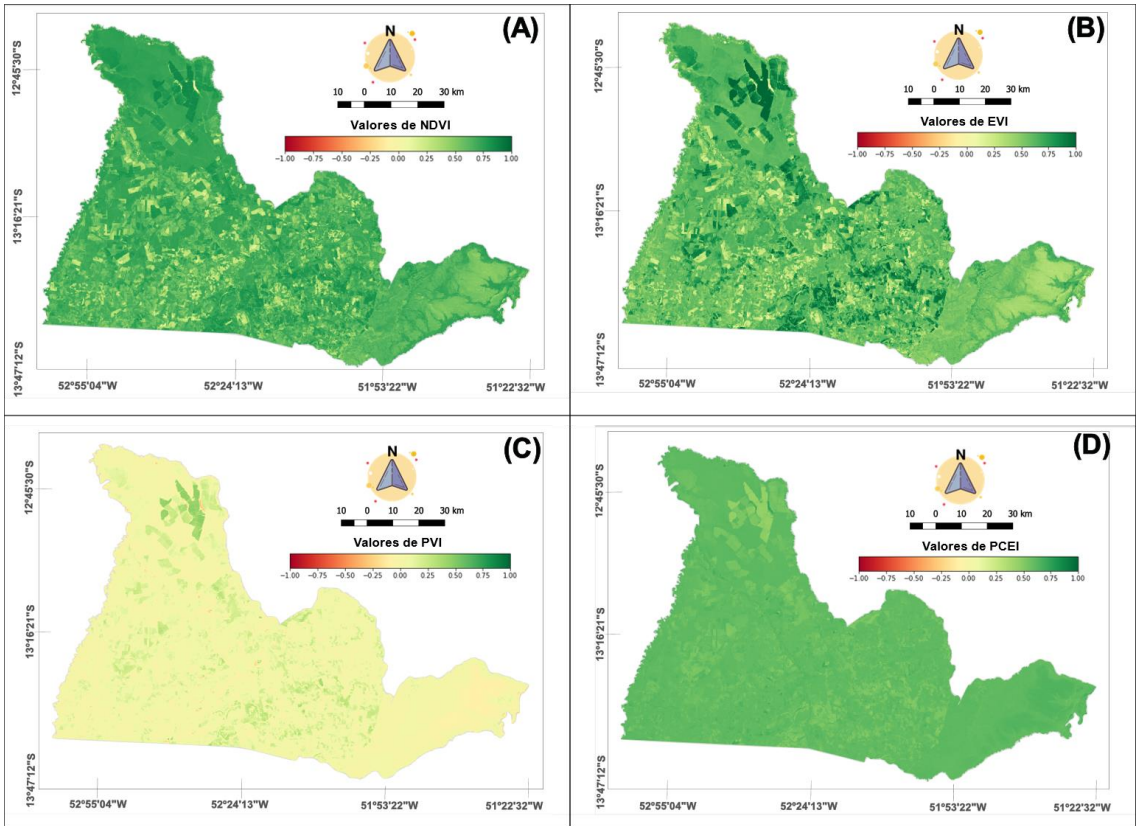

FIGURA 9: Índices de vegetação obtidos por meio do Sensor OLI *Landsat-8*: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor

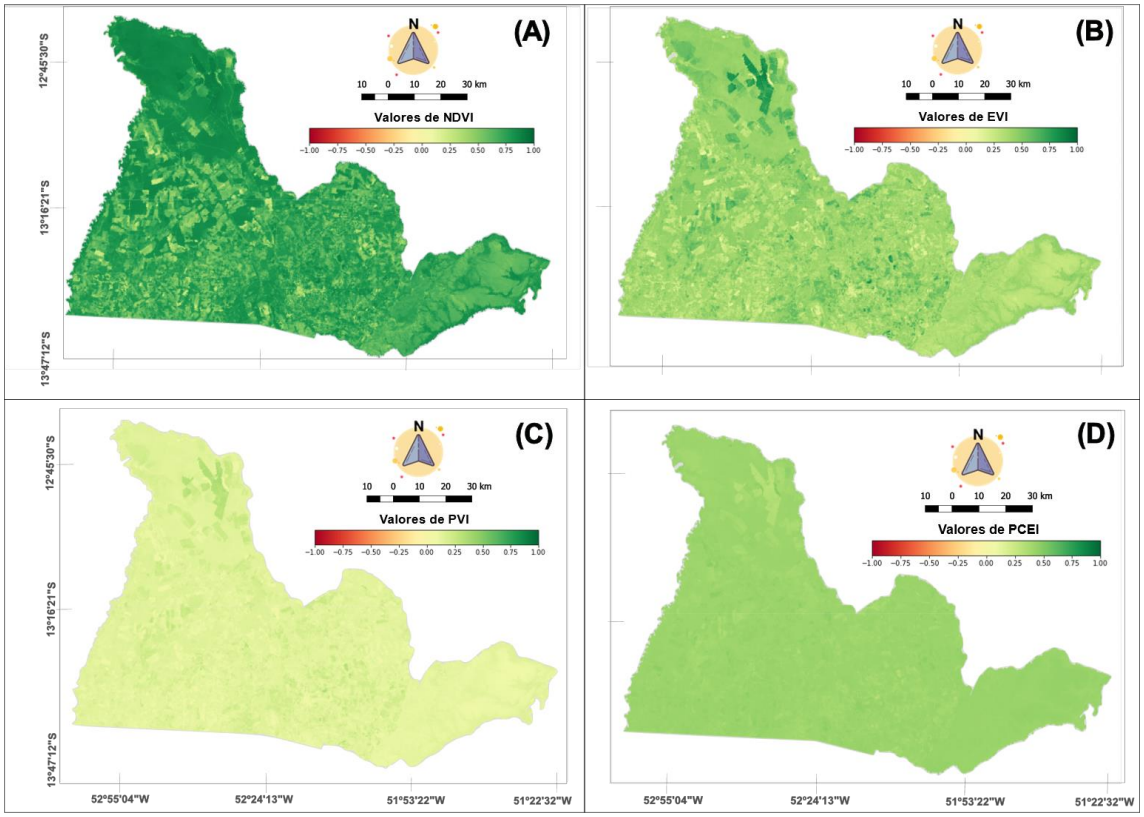

FIGURA 10: Índices de vegetação obtidos por meio do Sensor MODIS Terra: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor

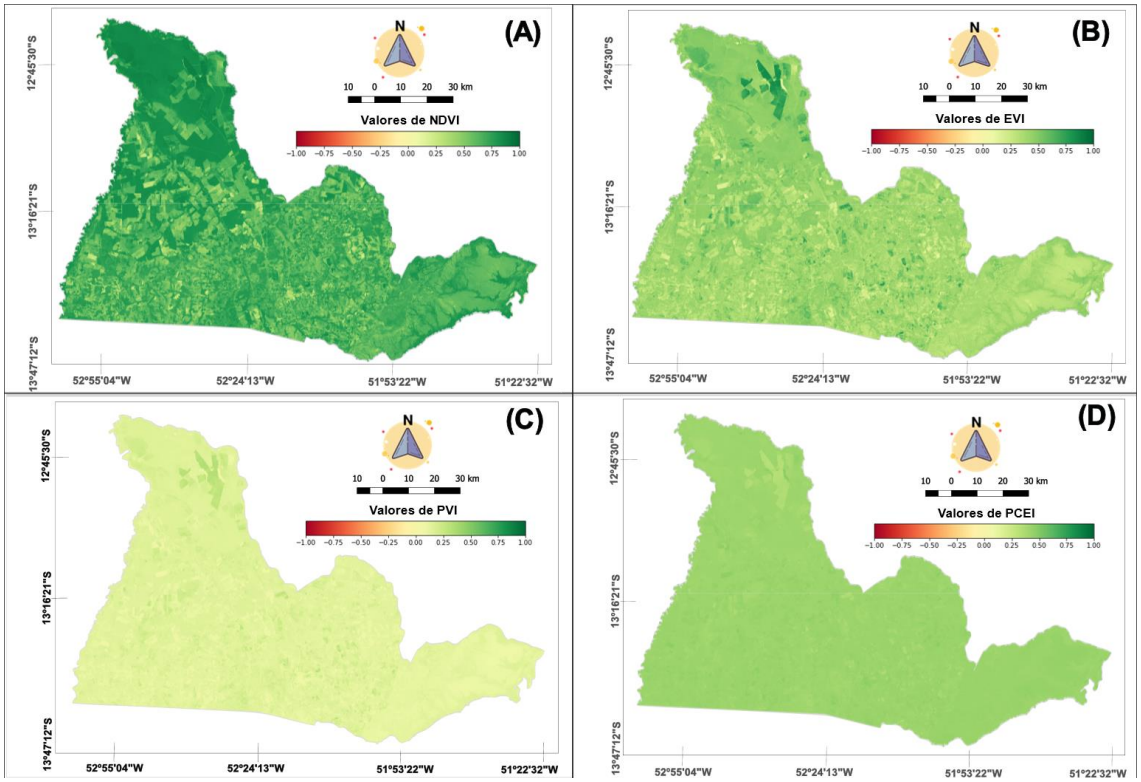

FIGURA 11: Índices de vegetação obtidos por meio das imagens *Planet* NICFI: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor

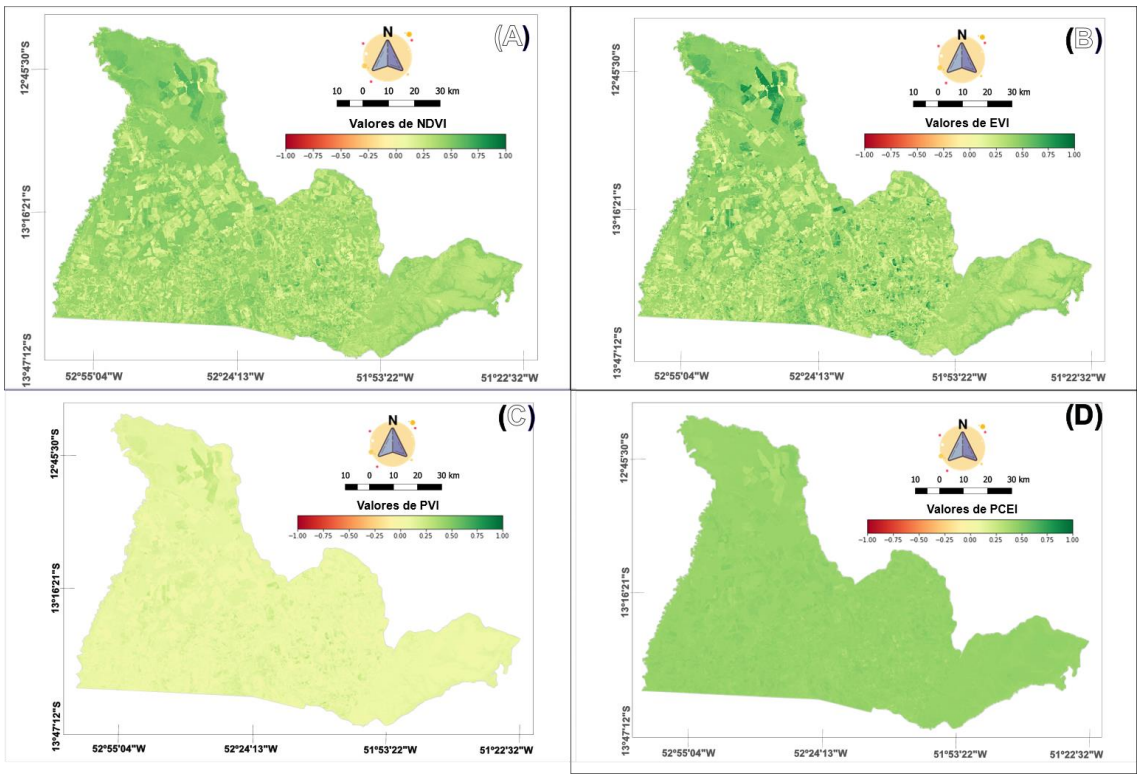

FIGURA 12: Índices de vegetação obtidos por meio do Sensor MSI *Sentinel-2*: (A) NDVI, (B) EVI, (C) PVI e (D) PCEI. Fonte: o autor

TABELA 1: Variação dos Componentes Principais do PCA dos 4 sensores

COMPONENTES PRINCIPAIS	Landsat8	MODIS	Planet	Sentinel 2
PC01	97,02%	94,52%	98,22%	95,28%
PC02	2,65%	4,31%	1,52%	4,51%
PC03	0,29%	1,08%	0,18%	0,15%
PC04	0,03%	0,04%	0,04%	0,03%
PC05	0,01%	0,03%	0,03%	0,02%
PC06	0,00%	0,02%	0,01%	0,01%
PC07	0,00%	0,00%	0,00%	0,00%
PC08	0,00%	0,00%	0,00%	0,00%
PC09	0,00%	0,00%	0,00%	0,00%
PC10	0,00%	0,00%	0,00%	0,00%
PC11	0,00%	0,00%	0,00%	0,00%
PC12	0,00%	-0,00%	0,00%	0,00%
PC13	0,00%	-0,00%	0,00%	0,00%
PC14	-0,00%	-0,00%	0,00%	-0,00%
PC15	-0,00%	-0,00%	0,00%	-0,00%
PC16	-0,00%	-0,00%	-0,00%	-0,00%

Fonte: o autor

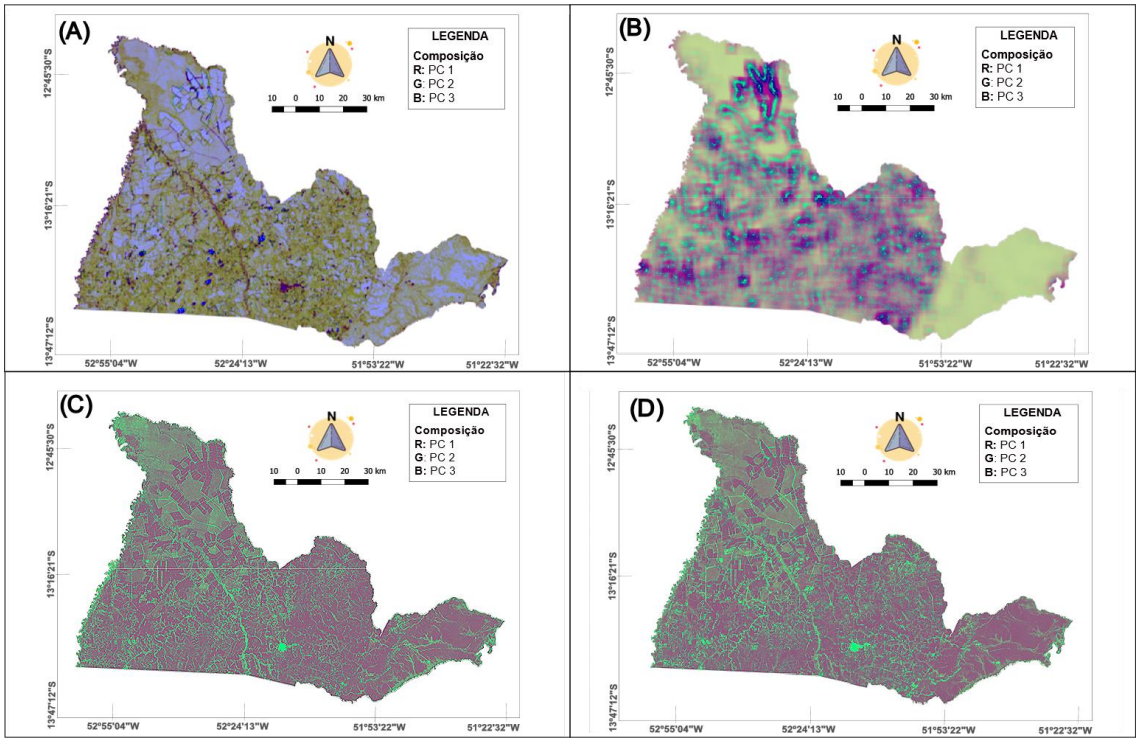

FIGURA 13: Mosaico das Análises de Componentes Principais (PCAs): (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Imagens *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

Posteriormente à etapa do PCA, obteve a segmentação das imagens baseado nos três componentes principais. A segmentação SNIC (FIGURA 14) resultou de forma muito eficaz em todas as imagens analisadas na delimitação dos objetos (TASSI; VIZZARI, 2020).

A combinação de elementos texturais com os índices de vegetação e as bandas originais das imagens aliada ao processo de PCA melhoram de forma substancial os resultados da segmentação, bem como ressaltado por TASSI et al. (2021) e TASSI; VIZZARI (2020).

Na etapa de segmentação, um dos fatores que podem ter influenciado os resultados foi a diminuição das resoluções espaciais das imagens do sensor MSI *Sentinel-2-AB* e da *Planet* NICFI para 30 m, em virtude do limite da capacidade de processamento da plataforma GEE na conta gratuita, visto que a plataforma é de uso global e por isso o acesso gratuito deva ser limitado (RUIZ et al., 2021; TASSI et al., 2021a; TASSI; VIZZARI, 2020; ZHANG et al., 2018).

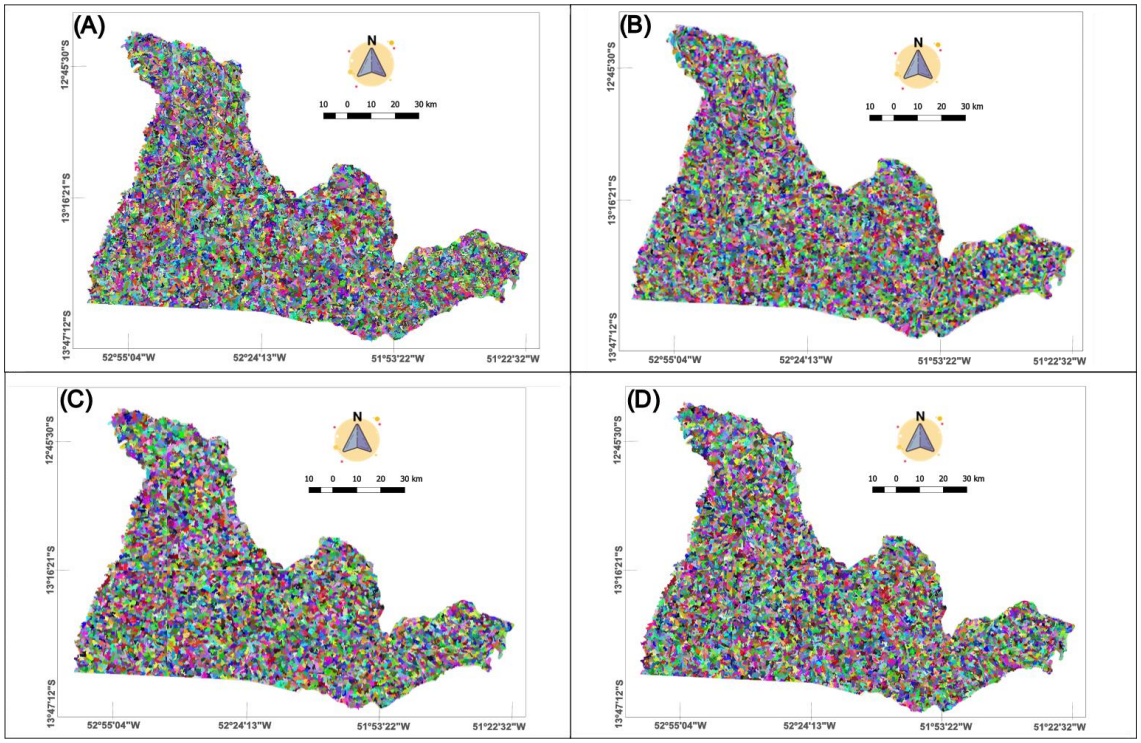

FIGURA 14: Imagens segmentadas pelo algoritmo SNIC no *Google Earth Engine* (GEE): (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Imagens *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

Em etapa anterior à classificação final do algoritmo, o teste de acurácia com diferentes números de árvores de decisão no *Random Forest* mostrou resultados distintos para os quatro sensores utilizados, sendo analisado um intervalo de 10 (dez) a 200 (duzentas) árvores, visto a combinação ideal em termos de precisão e custos computacionais (TASSI; VIZZARI, 2020).

Para as imagens *Landsat-8*, o número de 120 (cento e vinte); para a imagem MODIS,110 (cento e dez); para *Planet*, 150 (cento e cinquenta); e para *Sentinel-2* 180 (cento e oitenta) árvores obtiveram maior acurácia (FIGURA 15). Esse processo, avaliou concomitantemente a importância de cada banda das imagens para a classificação de uso e ocupação do solo (FIGURA 16), semelhante ao realizado por (TASSI; VIZZARI, 2020).

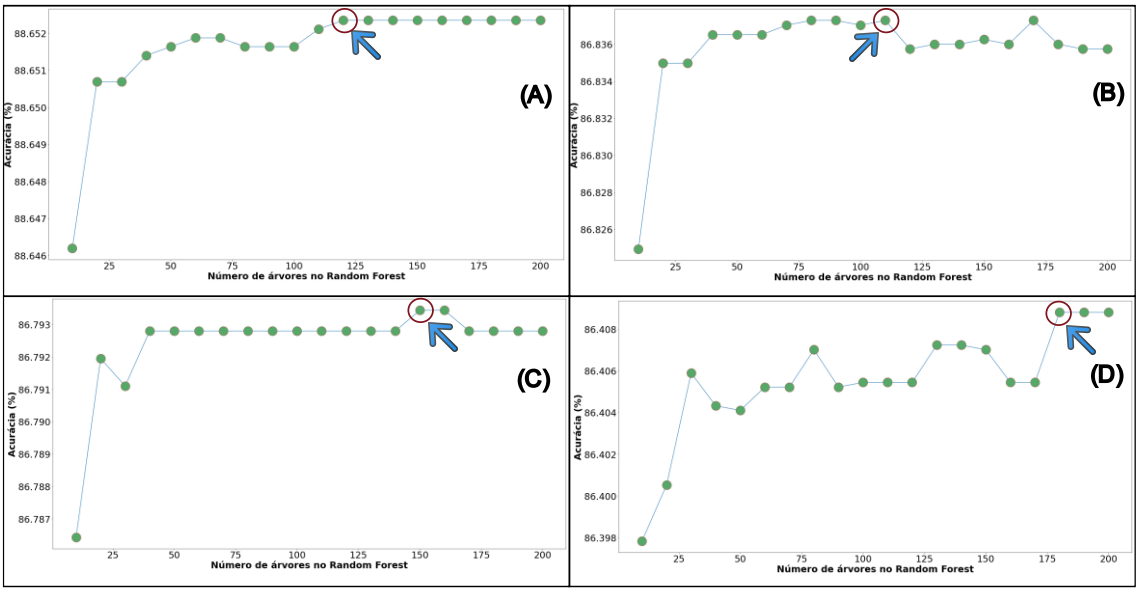

FIGURA 15: Teste de acurácia com diferentes números de árvores de decisão no *Random Forest*: (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Imagens *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

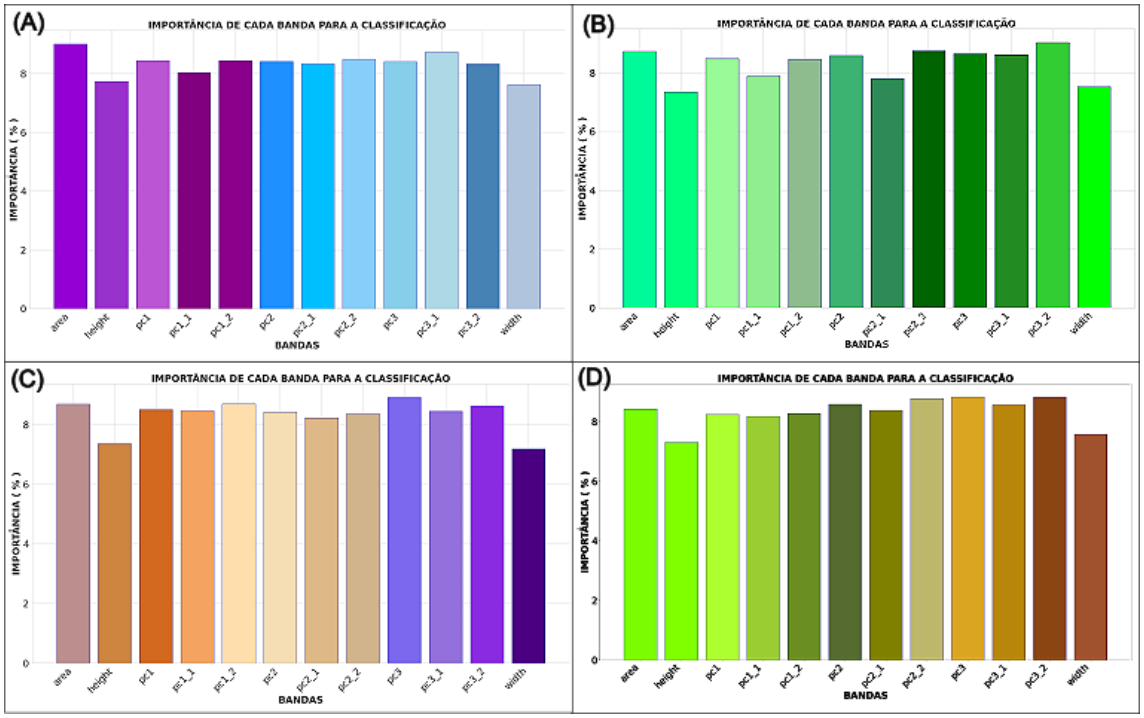

FIGURA 16: Importância de cada banda das imagens para a classificação de uso e ocupação do solo: (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Imagens *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

A partir dessa apuração, os dados classificados geraram as matrizes de confusão com AG variando de 86,41% a 88,65% (FIGURAS 17, 18, 19 e 20; TABELA 2). A imagem *Landsat* apresentou os maiores resultados, tendo sua AG

de 88,65% e 84,61% para o índice Kappa, dispondo das APs para as classes analisadas entre 65,16% e 91,53%, sendo a inferior para a classe Outros Usos do Solo e a superior correspondente a classe Milho Safrinha, a qual é o interesse deste estudo. Para a AC da classe supracitada o resultado foi de 91,98%, julgado como bom (IMANNI et al., 2022; MAXWELL et al., 2019; STROMANN et al., 2019).

Apesar da menor resolução espacial em relação aos outros sensores, as imagens MODIS apresentaram valores bem próximos aos do sensor OLI/*Landsat*, obtendo AG e Kappa de 86,83% e 82,01%, respectivamente, sendo a classe foco do estudo com AC de 90,85% e AP de 89,40%.

O resultado corrobora aos apresentados por RUIZ et al. (2021), TASSI et al. (2021a, b) e TASSI; VIZZARI (2020), que obtiveram AG e Kappa superiores ao MSI Sentinel-2 em algumas análises, indicando que os dados de alta resolução espacial nem sempre são superiores aos dados de baixa resolução na identificação dos usos do solo quando os objetos apresentam atributos complicados e variados.

Inesperadamente, o conjunto de dados *PlanetScope*, apesar da alta resolução espacial, produziu resultados gerais inferiores em comparação com o *Landsat-8*, mesma resposta obtida por TASSI e VIZZARI (2020) que explicaram que o resultado provavelmente está relacionado à menor resolução temporal e espectral (DELLA-SILVA et al., 2022) desse conjunto de dados e aos pontos de treinamento coletados de forma concentrada e não espalhadas por toda área de interesse. Essa combinação de fatores produziu informações escassas para diferenciar adequadamente as classes, sugerindo que a resolução espacial de 4,77 m não forneceu informações texturais suficientes para a separação efetiva das classes estudadas.

Os resultados das imagens da *Planet* NICFI em relação ao Sentinel-2, foram similares entre si tanto na AG de 86,79% e 86,41%, quanto o Kappa, 82,06% e 81,26%, respectivamente. Para a AC, os resultados foram superiores a 87%, e para a AP superiores a 89%.

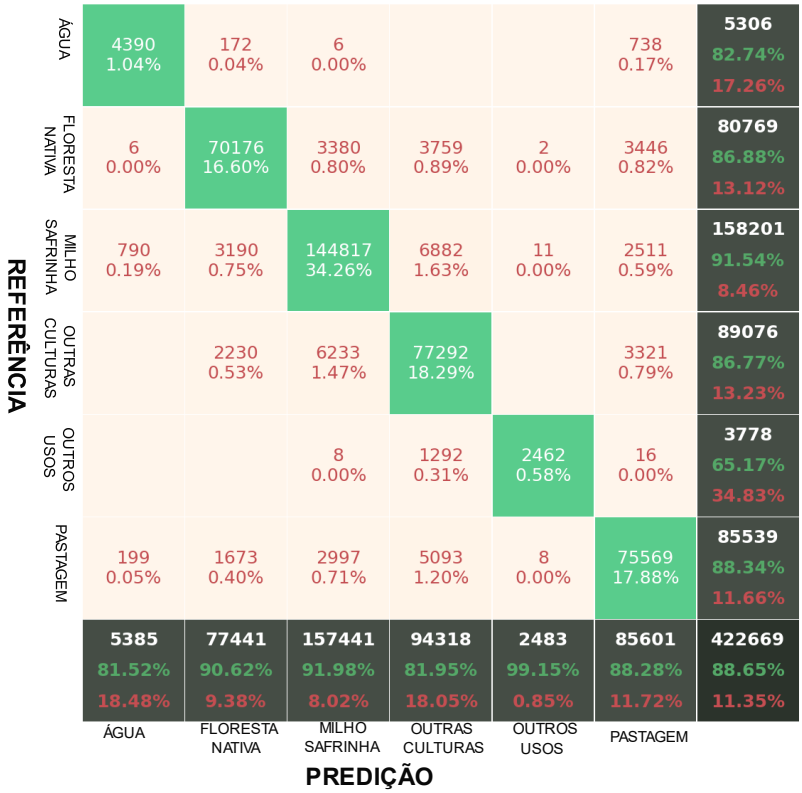

1

2 **FIGURA 17:** Matriz de Confusão para Sensor OLI *Landsat-8.* Fonte: o autor

3

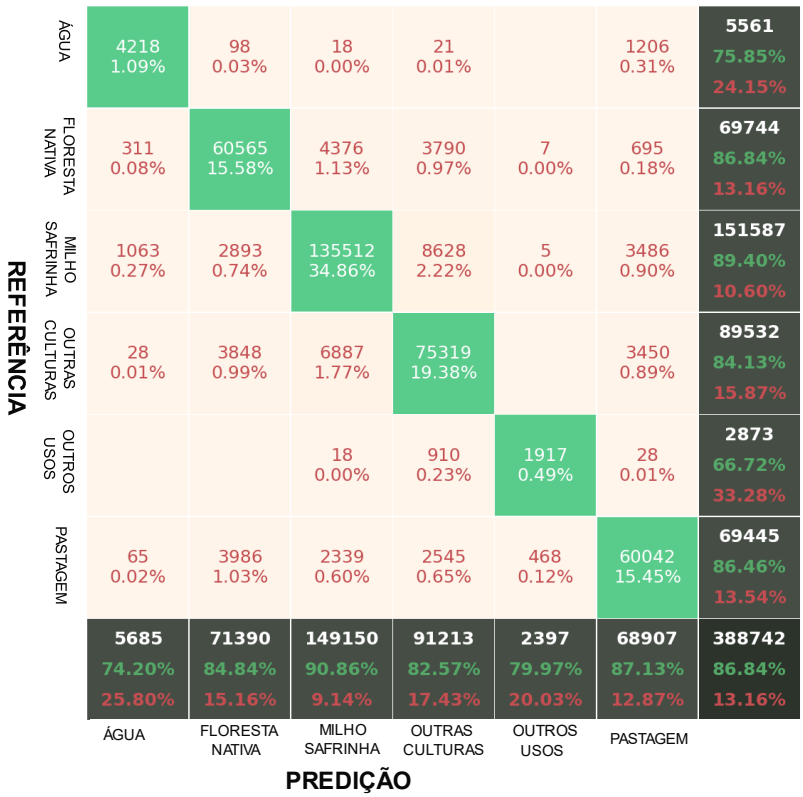

4

5 **FIGURA 18:** Matriz de Confusão para o Sensor MODIS Terra. Fonte: o autor

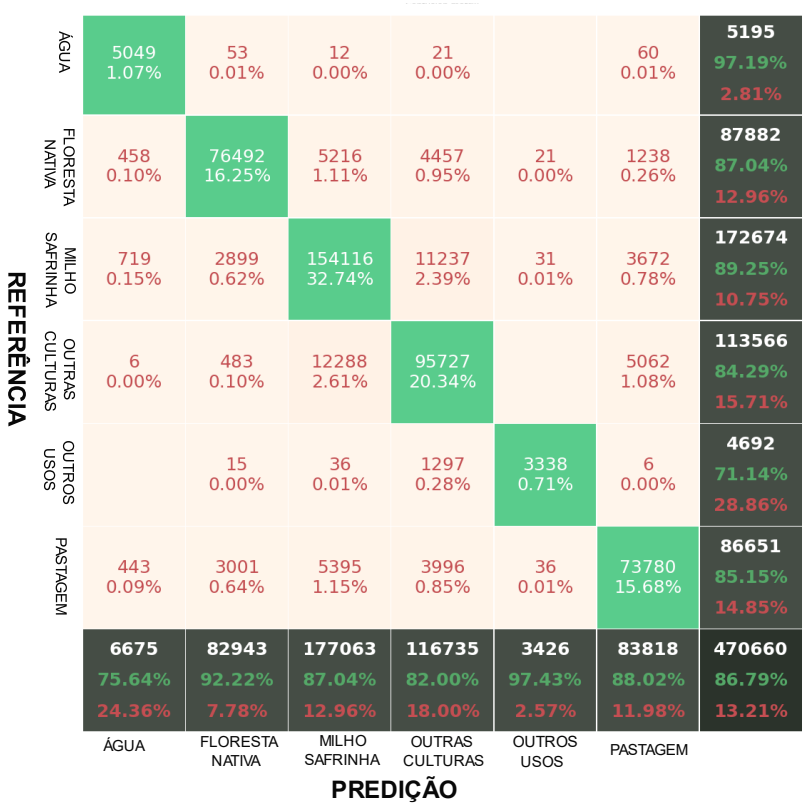

FIGURA 19: Matriz de Confusão para o Sensor *Planet* NICFI. Fonte: o autor

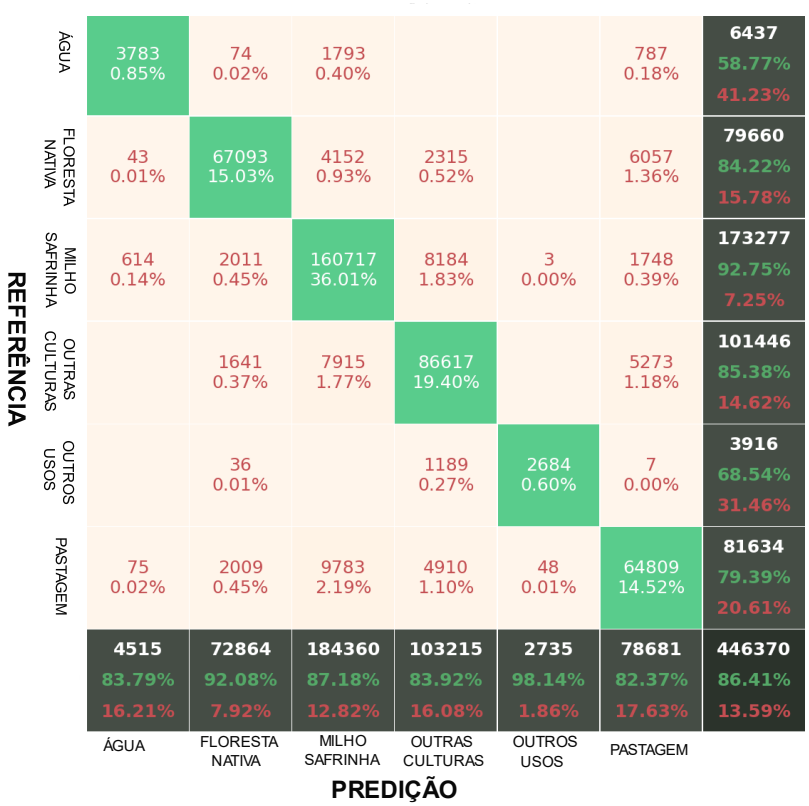

FIGURA 20: Matriz de Confusão para o Sensor MSI *Sentinel*-2. Fonte: o autor

TABELA 2: Acurácias Global (AGs) e índices Kappa da classificação dos 4 sensores analisados

	Landsat 8	MODIS	Planet	Sentinel 2
Acurácia Global (AG)	88,65%	86,83%	86,79%	86,41
Índice Kappa	84,61%	82,01%	82,06%	81,26%

Fonte: o autor

Desse modo, logrou-se a classificação de uso e ocupação do solo (FIGURAS 21, 22, 23, 24 e 25) para todos os quatro sensores avaliados. O efeito "sal e pimenta" foi observado com maior incidência nas imagens do MODIS Terra e *Landsat-8*, que pode ser explicado por resoluções espaciais inferiores ao *Sentinel-2* e *PlanetScope* (AI et al., 2022; MATARIRA; MUTANGA; NAIDU, 2022). Entretanto, nota-se que tais efeitos não afetam significativamente a classificação final das series avaliadas, e que provavelmente são superiores aos resultados das classificações produzidas pelos métodos baseados em *pixels*, conforme demonstrado por TASSI; VIZZARI (2020).

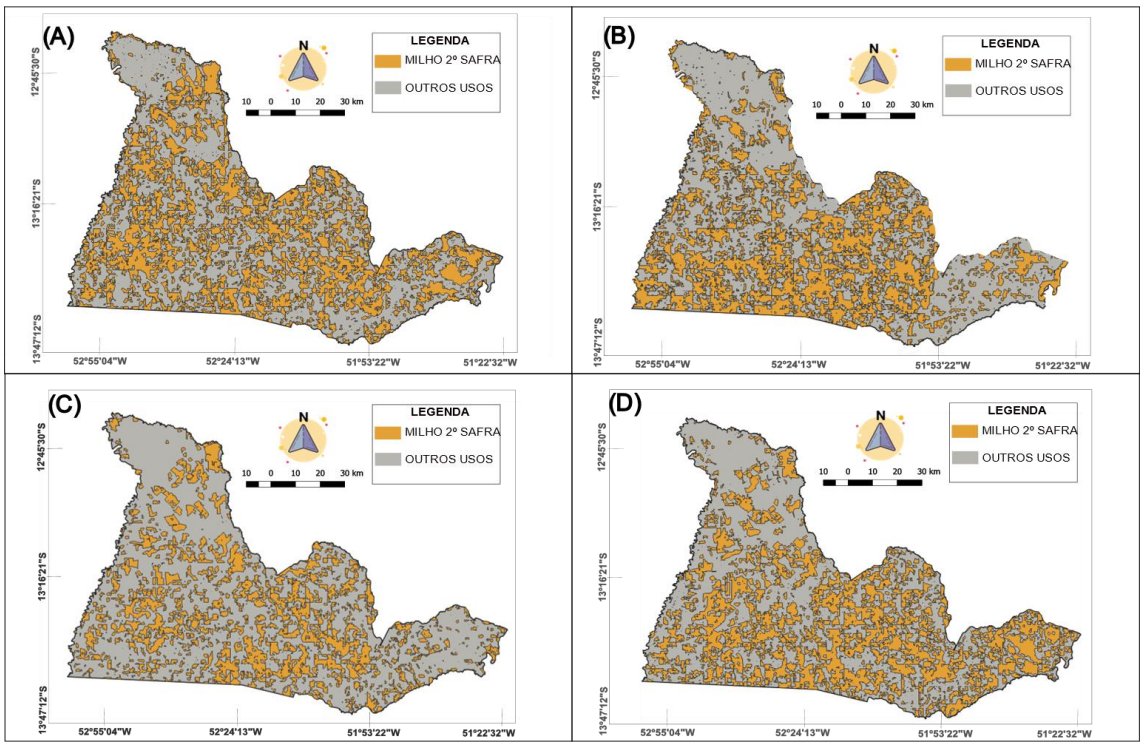

FIGURA 21: Classificação de Uso e Ocupação do solo utilizando a metodologia GEOBIA com o classificador *Random Forest* para os quatros sensores avaliados: (A) Sensor OLI *Landsat-8*, (B) Sensor MODIS Terra, (C) Sensor *Planet* NICFI e (D) Sensor MSI *Sentinel-2*. Fonte: o autor

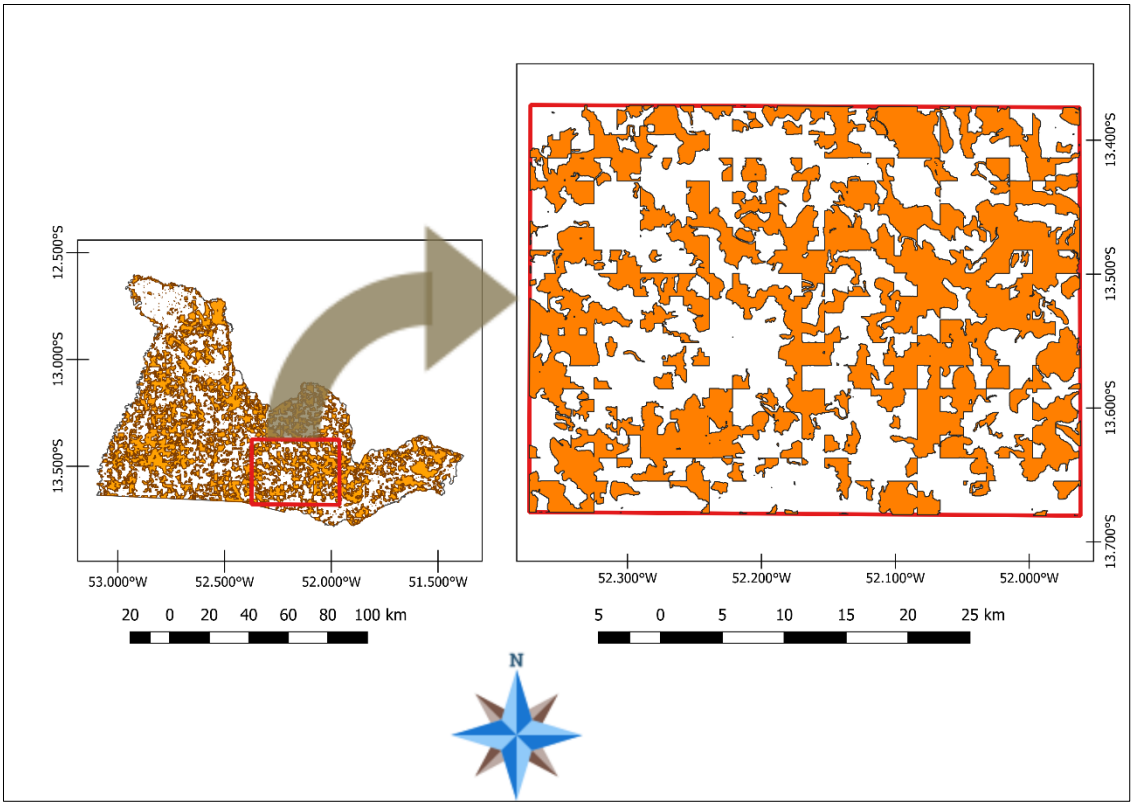

FIGURA 22: Recorte das áreas de milho 2ª safra classificadas pelo Sensor OLI Landsat-8. Fonte: o autor

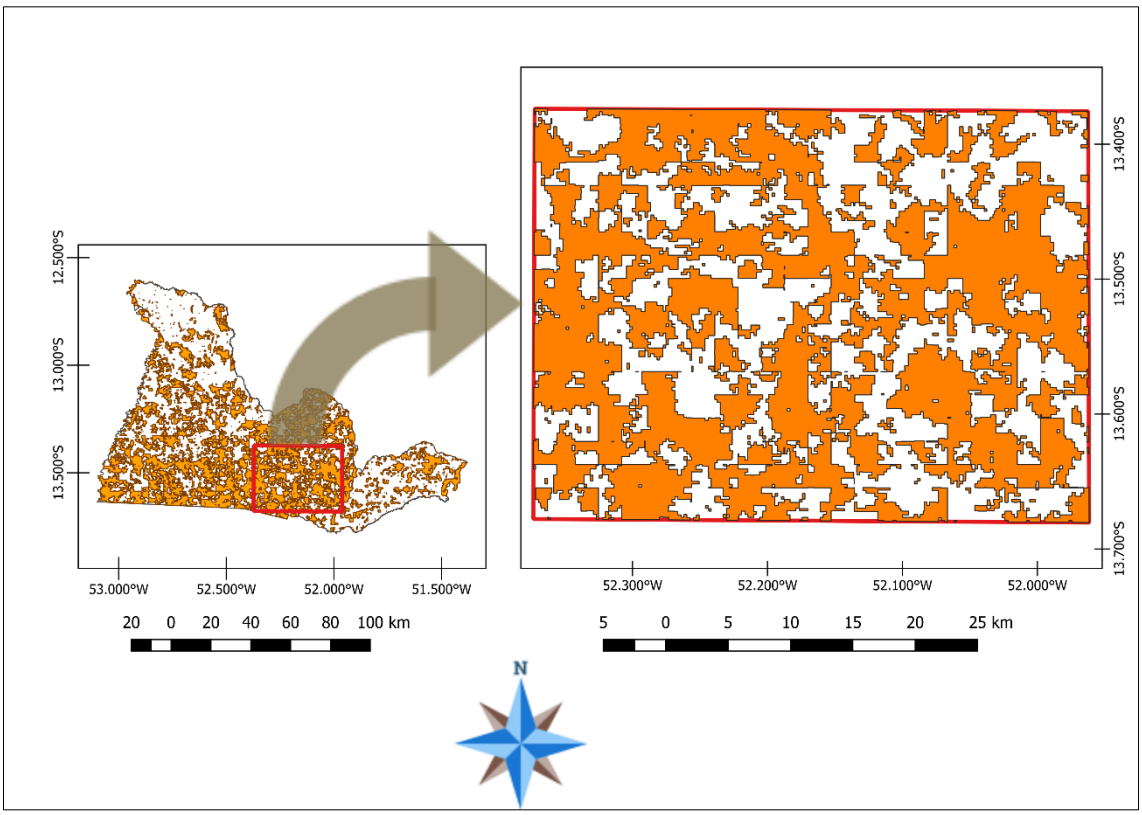

FIGURA 23: Recorte das áreas de milho 2ª safra classificadas pelo Sensor MODIS Terra. Fonte: o autor

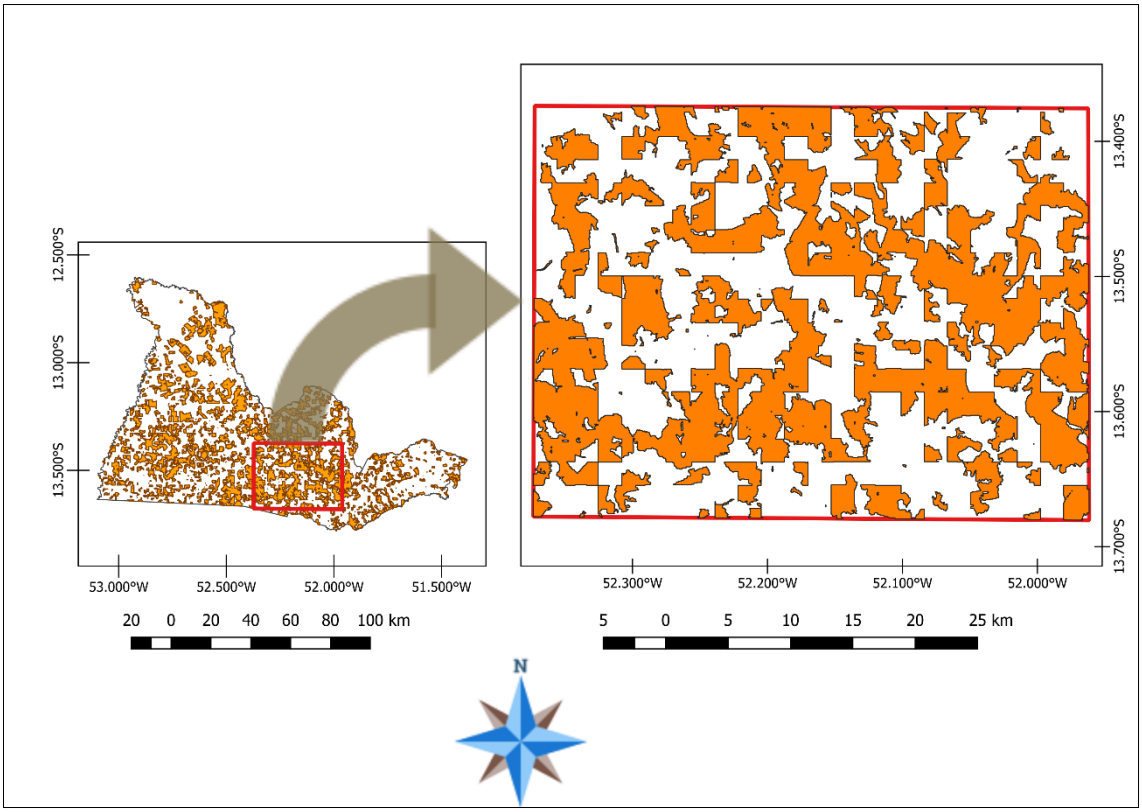

FIGURA 24: Recorte das áreas de milho 2ª safra classificadas pelo Sensor Planet NICFI. Fonte: o autor

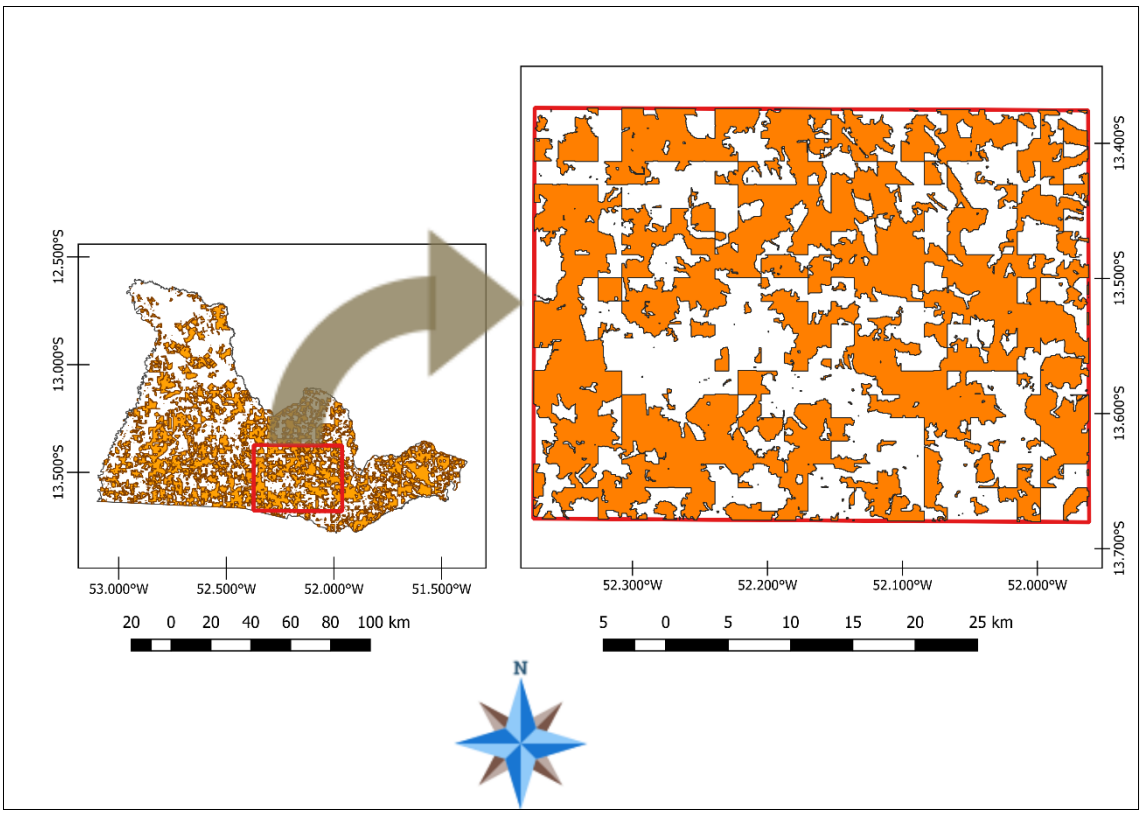

FIGURA 25: Recorte das áreas de milho 2ª safra classificadas pelo Sensor MSI Sentinel-2. Fonte: o autor

A TABELA 3 dispõe dados das áreas de cada classe classificada nas imagens analisadas. Para o milho safrinha, classe de interesse, as imagens dos satélites *Planet* resultaram na menor área, quantificando aproximadamente 330 mil ha. Assim sendo, a classificação das áreas de milho com as imagens Planet destoara dos resultados dos outros sensores, indicando que apesar da maior resolução espacial, o algoritmo de classificação confundiu a cultura do milho segunda safra com as outras culturas de segunda safra.

TABELA 3: Áreas (ha) das classes classificadas nos 4 sensores analisados

	ÁGUA (ha)	FLORESTA NATIVA (ha)	MILHO SAFRINHA (ha)	OUTRAS CULTURAS (ha)	OUTROS USOS (ha)	PASTAGEM (ha)
Landsat 8	2.060,08	344.104,74	450.766,60	123.195,41	1.966,13	162.199,05
MODIS	2.433,66	417.991,13	424.715,59	131.120,44	1.798,84	106.999,67
Planet	2.648,84	489.306,76	329.557,85	85.997,45	2.919,84	173.861,31
Sentinel 2	2.214,14	412.301,40	432.422,91	104.275,06	2.293,05	130.785,48

Fonte: o autor

As TABELAS 4 e 5 apresentam a análise de variância (Anova) e os teste de Tukey para a comparação de médias, respectivamente, utilizando os valores de AG e Kappa de cada classificação. Os resultados mostram que não há diferença significativa a 5% de probabilidade entre os resultados das classificações realizadas, implicando dizer que as respostas dos sensores foram estatisticamente semelhantes.

TABELA 4: Análise de Variância (ANOVA) com 5% de probabilidade realizada para os resultados de Acurácia Global e índice Kappa das classificações dos 4 (quatro) sensores

Variable	N	Mean	SD	SE	95% Conf.	Interval
MODIS	2	84,42	3,42	2,42	53,72	115,12
Landsat8	2	86,63	2,86	2,02	60,95	112,31
Planet	2	84,43	3,35	2,37	54,37	114,49
Sentinel 2	2	83,84	3,64	2,57	51,18	116,50

Fonte: o autor

TABELA 5: Comparação múltipla de médias pelo teste de Tukey HSD (5% de probabilidade) realizada para os resultados de Acurácia Global e índice Kappa das classificações dos quatro sensores

Group1	Group1	Meandiff	P-adj	Lower	Upper	Reject
Landsat8	MODIS	-2,2098	0,9	-15,7536	11,3339	False
Landsat8	Planet	-2,2037	0,9	-15,7474	11,34	False
Landsat8	Sentinel 2	-2,7929	0,8225	-16,3367	10,7508	False
MODIS	Planet	0,0061	0,9	-13,5376	13,5498	False
MODIS	Sentinel 2	-0,5831	0,9	-14,1268	12,9606	False
Planet	Sentinel 2	-0,5892	0,9	-14,1329	12,9545	False

Fonte: o autor

Para INGLADA et al. (2016), LUO; Liu et al. (2021) e IMANNI et al., (2022), a classificação em uma região agrícola altamente heterogênea e fragmentada é desafiadora devido as similaridades de refletância entre as culturas de segunda safra, bem como às diferentes resoluções temporais e espaciais das imagens empregadas. Diante dessa situação, os autores combinaram diversos tipos de imagens com resolução espacial e temporal, além de utilizarem imagens de séries temporais. Isto posto, alcançaram resultados significativamente superior aos obtidos pelas análises usando imagens mensais únicas separadas.

Com base nesses estudos, o resultado obtido nessa pesquisa, principalmente para as imagens *Landsat 8 e MODIS Terra*, é bem consistente em relação à acurácia da classificação, e remete a utilização em estudos posteriores da combinação das imagens supracitadas com as imagens *PlanetScope* NIFCI e *Sentinel-2*, como também outros sensores, a fim de alçar resultados mais afinados do que o presente estudo.

A obtenção dos resultados desse estudo deve-se aos conjuntos de dados de sensoriamento remoto de acesso aberto e o poder de computação da plataforma GEE, que demonstrou considerável versatilidade e adaptabilidade devido às suas capacidades integrativas e sua plataforma eficiente para a escrita de scripts em linguagem *JavaScript* e *Python*. O presente estudo teve como fundamento a utilização das tecnologias de código aberto com foco em processos que sejam robustos e escaláveis em grandes extensões espaciais, e obteve-se bons resultados.

6. CONCLUSÃO

As avaliações realizadas mostraram resultados satisfatórios, uma vez que o índice Kappa e AG apresentaram valores superiores a 80%. Portanto, conclui-se que a metodologia GEOBIA, que empregou a combinação SNIC + GLCM com o classificador *Random Forest*, foi bem-sucedida. No entanto, é importante destacar que ainda há espaço para melhorias na etapa de segmentação, a fim de tornar a metodologia aplicável em grandes áreas agrícolas.

Ademais, este estudo ressaltou a confiabilidade geral da metodologia GEOBIA, embora sua complexidade resulte em maior exigência computacional. Isso pode afetar a execução do código GEE, especialmente quando se utilizam dados de alta resolução espacial, como Sentinel-2 e PlanetScope.

7. SUGESTÃO PARA TRABALHOS FUTUROS

A utilização do algoritmo de segmentação SNIC pode ter sido um dos motivos para a falta de diferença significativa entre os sensores. Pesquisas futuras podem se beneficiar da utilização de outros segmentadores disponibilizados pelo GEE, como GMeans e KMeans, que podem proporcionar resultados melhores. Além disso, é recomendável a utilização de séries temporais de imagens em suas resoluções originais, bem como a combinação de dados provenientes de diferentes sensores. Essas medidas podem aprimorar a metodologia e proporcionar resultados mais precisos.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABBASZADEH, Maryam; MAHDAVI, Rasool; REZAI, Marzieh. Assessment of sedimentation process in flood water spreading system using IRS (P5) and supervised classification algorithms (case study: Dahandar plain, Minab city, south of Iran). **Remote Sensing Applications: Society and Environment**, v. 16, n. May, p. 100269, 2019.

ACHANTA, Radhakrishna; SUSSTRUNK, Sabine. Superpixels and Polygons Using Simple Non-iterative Clustering. jul. 2017, [S.l.]: IEEE, jul. 2017. p. 4895–4904.

ADAMI, Marcos et al. Amostragem probabilística estratificada por pontos para estimar a área cultivada com soja. **Pesquisa Agropecuária Brasileira**, v. 45, n. 6, p. 585–592, jun. 2010.

ADUVUKHA, Grace Rebecca et al. Cropping Pattern Mapping in an Agro-Natural Heterogeneous Landscape Using Sentinel-2 and Sentinel-1 Satellite Datasets. **Agriculture**, v. 11, n. 6, p. 530, 7 jun. 2021.

AI, Bin et al. Comparison of Classification Algorithms for Detecting Typical Coastal Reclamation in Guangdong Province with Landsat 8 and Sentinel 2 Images. **Remote Sensing**, v. 14, n. 2, p. 385, 14 jan. 2022.

ALVES, Heber Queiroz; REZENDE, Ana Carolina Pinto; SPOSITO, Rafael de Carvalho. Geoprocessamento como Ferramenta de Conservação de Recursos Hídricos e de Biodiversidade: Um Estudo de Caso para o Município de Canarana – MT. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, INPE**, p. 3439–3446, 2009.

AMANI, Meisam et al. Application of Google Earth Engine Cloud Computing Platform, Sentinel Imagery, and Neural Networks for Crop Mapping in Canada. **Remote Sensing**, v. 12, n. 21, p. 3561, 30 out. 2020.

ANDERS, Niels S.; SEIJMONSBERGEN, Arie C.; BOUTEN, Willem. Segmentation optimization and stratified object-based analysis for semi-automated

geomorphological mapping. **Remote Sensing of Environment**, v. 115, n. 12, p. 2976–2985, 2011.

ANEECE, Itiya; THENKABAIL, Prasad. Accuracies Achieved in Classifying Five Leading World Crop Types and their Growth Stages Using Optimal Earth Observing-1 Hyperion Hyperspectral Narrowbands on Google Earth Engine. **Remote Sensing**, v. 10, n. 12, p. 2027, 13 dez. 2018.

BARROS, José F. C.; CALADO, José G. DEPARTAMENTO DE FITOTECNIA A Cultura do Milho. **Book**, p. 1–52, 2014.

BELCORE, E.; PIRAS, M.; WOZNIAK, E. SPECIFIC ALPINE ENVIRONMENT LAND COVER CLASSIFICATION METHODOLOGY: GOOGLE EARTH ENGINE PROCESSING FOR SENTINEL-2 DATA. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B3-2, n. B3, p. 663–670, 21 ago. 2020.

BELGIU, Mariana; CSILLIK, Ovidiu. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**, v. 204, n. November 2017, p. 509–523, jan. 2018.

BELGIU, Mariana; DRĂGUŢ, Lucian. Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 96, p. 67–75, out. 2014.

BERGAMASCHI, Homero et al. Deficit hídrico e produtividade na cultura do milho. **Pesquisa Agropecuária Brasileira**, v. 41, n. 2, p. 243–249, fev. 2006.

BERNARDES, Tiago et al. Imagens mono e multitemporais Modis para estimativa da área com soja no estado de Mato Grosso. **Pesquisa Agropecuária Brasileira**, v. 46, n. 11, p. 1530–1537, nov. 2011.

BERTOLIN, Natalia de Oliveira et al. PREDIÇÃO DA PRODUTIVIDADE DE MILHO IRRIGADO COM AUXÍLIO DE IMAGENS DE SATÉLITE. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 4, p. 1627–1638, 10 nov. 2017.

BHUSHAN, Shashank et al. Automated digital elevation model (DEM) generation from very-high-resolution Planet SkySat triplet stereo and video imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, n. July 2020, p. 151–165, mar. 2021.

BLASCHKE, Thomas et al. Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, jan. 2014.

BRIGHT, Jamie M.; GUEYMARD, Christian A. Climate-specific and global validation of MODIS Aqua and Terra aerosol optical depth at 452 AERONET stations. **Solar Energy**, v. 183, n. March, p. 594–605, 2019.

BURNS, Patrick; MACANDER, Matt. **Topographic correction in GEE**. Disponível em: <https://mygeoblog.com/2018/10/17/terrain-correction-in-gee/>. Acesso em: 3 jul. 2021.

CABALLERO, Isabel; NAVARRO, Gabriel. Monitoring cyanoHABs and water quality in Laguna Lake (Philippines) with Sentinel-2 satellites during the 2020 Pacific typhoon season. **Science of The Total Environment**, v. 788, p. 147700, 2021.

CABALLERO, Isabel; STUMPF, Richard P. Retrieval of nearshore bathymetry from Sentinel-2A and 2B satellites in South Florida coastal waters. **Estuarine, Coastal and Shelf Science**, v. 226, n. June, p. 106277, 2019.

CAMACHO, Fernando et al. Crop specific algorithms trained over ground measurements provide the best performance for GAI and fAPAR estimates from Landsat-8 observations. **Remote Sensing of Environment**, v. 260, n. March, p. 112453, 2021.

CASTILLEJO-GONZÁLEZ, Isabel Luisa et al. Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery. **Computers and Electronics in Agriculture**, v. 68, n. 2, p. 207–215, out. 2009.

CHANDER, Gyanesh et al. Monitoring on-orbit calibration stability of the Terra MODIS and Landsat 7 ETM+ sensors using pseudo-invariant test sites. **Remote Sensing of Environment**, v. 114, n. 4, p. 925–939, 2010.

CHASTAIN, Robert et al. Empirical cross sensor comparison of Sentinel-2A and 2B MSI, Landsat-8 OLI, and Landsat-7 ETM+ top of atmosphere spectral characteristics over the conterminous United States. **Remote Sensing of Environment**, v. 221, n. November 2018, p. 274–285, 2019.

CHENG, Tao et al. DESTIN: A new method for delineating the boundaries of crop fields by fusing spatial and temporal information from WorldView and Planet satellite imagery. **Computers and Electronics in Agriculture**, v. 178, n. April, p. 105787, 2020.

CHENG, Xinmeng et al. Extraction of Mountain Grasslands in Yunnan, China, from Sentinel-2 Data during the Optimal Phenological Period Using Feature Optimization. **Agronomy**, v. 12, n. 8, p. 1948, 18 ago. 2022.

COMEXSTAT. **Exportação e Importação Geral**. Disponível em: <http://comexstat.mdic.gov.br/pt/geral/37761>. Acesso em: 5 jul. 2021.

CONAB. Acompanhamento da Safra Brasileira. **Companhia Nacional de Abastecimento: Acompanhamento da Safra Brasileira**, v. 7, n. 6, p. 1–89, 2022.

_____. Acompanhamento da Safra Brasileira – Safra 2022/23 n.4 - Quarto levantamento. **Companhia Nacional de Abastecimento: Acompanhamento da Safra Brasileira**, v. 10, n. 6, p. 1–83, jan. 2023.

CROSSON, William L. et al. A daily merged MODIS Aqua-Terra land surface temperature data set for the conterminous United States. **Remote Sensing of Environment**, v. 119, p. 315–324, 2012.

SILVA JUNIOR, Carlos Antonio da et al. Vegetation Indices for Discrimination of Soybean Areas: A New Approach. **Agronomy Journal**, v. 109, n. 4, p. 1331–1343, jul. 2017. Disponível em: <http://doi.wiley.com/10.2134/agronj2017.01.0003>.

DA SILVA JUNIOR, Carlos Antonio et al. Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics and Technology**, v. 89, p. 338–350, 2018.

DELLA-SILVA, João Lucas et al. CO2Flux Model Assessment and Comparison between an Airborne Hyperspectral Sensor and Orbital Multispectral Imagery in Southern Amazonia. **Sustainability**, v. 14, n. 9, p. 5458, 1 maio 2022.

DRĂGUŢ, L. et al. Automated parameterisation for multi-scale image segmentation on multiple layers. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 119–127, fev. 2014.

ĐURIĆ, Nataša; PEHANI, Peter; OŠTIR, Krištof. Application of In-Segment Multiple Sampling in Object-Based Classification. **Remote Sensing**, v. 6, n. 12, p. 12138–12165, 5 dez. 2014.

DUVEILLER, Gregory et al. Spatial homogeneity from temporal stability: Exploiting the combined hyper-frequent revisit of Terra and Aqua to guide Earth System Science. **Remote Sensing of Environment**, v. 261, n. July 2020, p. 112496, 2021.

E. D. CHAVES, Michel; C. A. PICOLI, Michelle; D. SANCHES, Ieda. Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review. **Remote Sensing**, v. 12, n. 18, p. 3062, 18 set. 2020.

ESTORNELL, Javier et al. Principal component analysis applied to remote sensing. **Modelling in Science Education and Learning**, v. 6, p. 83, 2 jun. 2013.

FEIZIZADEH, Bakhtiar et al. An object based image analysis applied for volcanic and glacial landforms mapping in Sahand Mountain, Iran. **CATENA**, v. 198, n. November 2020, p. 105073, mar. 2021.

FERREIRA, J C V et al. **Mato Grosso e seus municípios**. [S.l.]: Editora Buriti, 2001.

FONSECA, Leila M.G. et al. Pattern Recognition and Remote Sensing techniques applied to Land Use and Land Cover mapping in the Brazilian Savannah. **Pattern Recognition Letters**, v. 148, p. 54–60, 2021.

FONTANA, Denise Cybis et al. Estimativa da radiação fotossinteticamente ativa absorvida pela cultura da soja através de dados do sensor Modis. **Bragantia**, v. 71, n. 4, p. 563–571, 2012.

GADIOLI, João Luiz et al. Temperatura do ar, rendimento de grãos de milho e caracterização fenológica associada à soma calórica. **Scientia Agricola**, v. 57, n. 3, p. 377–383, set. 2000.

GALVÃO, João Carlos Cardoso et al. Sete décadas de evolução do sistema produtivo da cultura do milho. **Revista Ceres**, v. 61, n. suppl, p. 819–828, dez. 2014.

GARCIA, Y. M. et al. DECLIVIDADE E POTENCIAL PARA MECANIZAÇÃO AGRÍCOLA DA BACIA HIDROGRÁFICA DO RIBEIRÃO PEDERNEIRAS - PEDERNEIRAS/SP. **Revista Brasileira de Engenharia de Biossistemas**, v. 14, n. 1, p. 62–72, 31 mar. 2020.

GHREFAT, Habes et al. Utilization of multispectral landsat-8 remote sensing data for lithological mapping of southwestern Saudi Arabia. **Journal of King Saud University - Science**, v. 33, n. 4, p. 101414, 2021.

GOOGLE EARTH ENGINE. **Google Earth Engine Platform**. Disponível em: <https://earthengine.google.com/platform/>. Acesso em: 21 jan. 2023.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, dez. 2017.

HAY CHUNG, Lamuel Chi; XIE, Jing; REN, Chao. Improved machine-learning mapping of local climate zones in metropolitan areas using composite Earth observation data in Google Earth Engine. **Building and Environment**, v. 199, n. March, p. 107879, 2021a.

_____. Improved machine-learning mapping of local climate zones in metropolitan areas using composite Earth observation data in Google Earth Engine. **Building and Environment**, v. 199, n. March, p. 107879, 2021b.

GARCÍA, David. Analysis and precision of the Terrestrial Surface Temperature using Landsat 8 and Sentinel 3 images: Study applied to the city of Granada (Spain).

Sustainable Cities and Society, v. 71, p. 102980, ago. 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2210670721002663>.

HOUBORG, Rasmus; MCCABE, Matthew F. A Cubesat enabled Spatio-Temporal Enhancement Method (CESTEM) utilizing Planet, Landsat and MODIS data. **Remote Sensing of Environment**, v. 209, n. March, p. 211–226, 2018.

HUANG, Yanbo et al. Agricultural remote sensing big data: Management and applications. **Journal of Integrative Agriculture**, v. 17, n. 9, p. 1915–1931, 2018.

IBGE. Anuário estatístico do Brasil. p. 533, 1947.

_____. **Cidades e Estados - Instituto Brasileiro de Geografia e Estatística**. Disponível em: <https://cidades.ibge.gov.br/brasil/mt/canarana/panorama>. Acesso em: 24 jun. 2021.

IMANNI, Hajar Saad El et al. Rapid and Automated Approach for Early Crop Mapping Using Sentinel-1 and Sentinel-2 on Google Earth Engine; A Case of a Highly Heterogeneous and Fragmented Agricultural Region. **Journal of Imaging**, v. 8, n. 12, p. 316, 24 nov. 2022. Disponível em: <https://www.mdpi.com/2313-433X/8/12/316>.

INGLADA, Jordi et al. Improved Early Crop Type Identification By Joint Use of High Temporal Resolution SAR And Optical Image Time Series. **Remote Sensing**, v. 8, n. 5, p. 362, 26 abr. 2016.

JAMALI, Ali. Evaluation and comparison of eight machine learning models in land use/land cover mapping using Landsat 8 OLI: a case study of the northern region of Iran. **SN Applied Sciences**, v. 1, n. 11, p. 1448, 21 nov. 2019.

JANOUŠEK, Jiří et al. Using UAV-Based Photogrammetry to Obtain Correlation between the Vegetation Indices and Chemical Analysis of Agricultural Crops. **Remote Sensing**, v. 13, n. 10, p. 1878, 11 maio 2021.

JIA, X.; RICHARDS, J.A. Segmented principal components transformation for efficient hyperspectral remote-sensing image display and classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 1, p. 538–542, 1999.

JIN, Song et al. River body extraction from sentinel-2A/B MSI images based on an adaptive multi-scale region growth method. **Remote Sensing of Environment**, v. 255, n. July 2020, p. 112297, mar. 2021.

JUNG, Jinha et al. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. **Current Opinion in Biotechnology**, v. 70, p. 15–22, 2021.

SILVA JUNIOR, Carlos Antonio da et al. Comparação de áreas de soja (Glycinemax (L) Merr.) obtidas por meio da interpretação de imagens TM/Landsat e MODIS/Terra no município de Maracaju (MS) = Comparison of areas of soybean (Glycine max (L) Merr.) obtained through the interpretation... **Bioscience Journal**, v. 30, n. 5, p. 707–716, 2014. Disponível em: <http://www.seer.ufu.br/index.php/biosciencejournal/article/view/19738>.

JUNIOR, Carlos Antonio da Silva et al. Sojamaps: Project of Monitoring of Soybean Areas in Brazil Using Big Data in the Cloud Computing. **XIX SBSR - Simpósio Brasileiro de Sensoriamento Remoto**, n. Abril, p. 1334–1337, 2019.

KHADIM, Fahad Khan et al. Soil salinity mapping in Everglades National Park using remote sensing techniques and vegetation salt tolerance. **Physics and Chemistry of the Earth**, v. 110, n. December 2018, p. 31–50, 2019.

KHAROL, Shailesh Kumar et al. Multiyear analysis of Terra/Aqua MODIS aerosol optical depth and ground observations over tropical urban region of Hyderabad, India. **Atmospheric Environment**, v. 45, n. 8, p. 1532–1542, 2011.

KUMAR, Amit et al. Field hyperspectral data analysis for discriminating spectral behavior of tea plantations under various management practices. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, n. 1, p. 352–359, 2013.

LAMQUIN, Nicolas et al. An inter-comparison exercise of Sentinel-2 radiometric validations assessed by independent expert groups. **Remote Sensing of Environment**, v. 233, n. August, p. 111369, nov. 2019.

LANDSAT-8. **Landsat 8 Overview**. Disponível em: <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>. Acesso em: 15 jun. 2021.

LANDSAT-9. **Landsat 9 - Landsat Science**. Disponível em: <https://landsat.gsfc.nasa.gov/landsat-9>.

LI, Jiwei et al. Adaptive bathymetry estimation for shallow coastal waters using Planet Dove satellites. **Remote Sensing of Environment**, v. 232, n. May, p. 111302, 2019.

LIMA, Mendelson et al. The “New Transamazonian Highway”: BR-319 and Its Current Environmental Degradation. **Sustainability**, v. 14, n. 2, p. 823, 12 jan. 2022.

LIMAN HAROU, Issoufou et al. Mapping Flood-Based Farming Systems with Bayesian Networks. **Land**, v. 9, n. 10, p. 369, 2 out. 2020.

LIU, Chang an et al. Research advances of SAR remote sensing for agriculture applications: A review. **Journal of Integrative Agriculture**, v. 18, n. 3, p. 506–525, 2019.

LUO, Chong; LIU, Huan-jun; et al. Monthly composites from Sentinel-1 and Sentinel-2 images for regional major crop mapping with Google Earth Engine. **Journal of Integrative Agriculture**, v. 20, n. 7, p. 1944–1957, jul. 2021.

LUO, Chong; QI, Beisong; et al. Using Time Series Sentinel-1 Images for Object-Oriented Crop Classification in Google Earth Engine. **Remote Sensing**, v. 13, n. 4, p. 561, 4 fev. 2021.

MA, Lei et al. A review of supervised object-based land-cover image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 277–293, 2017.

MANANZE, Sosdito; PÔÇAS, Isabel; CUNHA, Mário. Mapping and Assessing the Dynamics of Shifting Agricultural Landscapes Using Google Earth Engine Cloud Computing, a Case Study in Mozambique. **Remote Sensing**, v. 12, n. 8, p. 1279, 17 abr. 2020.

MANZATTO, Celso Vainer et al. Zoneamento Agroecológico da Cana-de-Açúcar Expandir a produção, preservar a vida, garantir o futuro. **EMBRAPA**, 2009.

MAPBIOMAS. **MAPAS DE REFERÊNCIA**. Disponível em: <https://mapbiomas.org/mapas-de-referencia>. Acesso em: 10 jul. 2021.

MASEK, Jeffrey G. et al. Landsat 9: Empowering open science and applications through continuity. **Remote Sensing of Environment**, v. 248, n. June, p. 111968, 2020.

MATARIRA, Dadirai; MUTANGA, Onisimo; NAIDU, Maheshvari. Google Earth Engine for Informal Settlement Mapping: A Random Forest Classification Using Spectral and Textural Information. **Remote Sensing**, v. 14, n. 20, p. 5130, 14 out. 2022.

MAXWELL, Aaron E. et al. Large-Area, High Spatial Resolution Land Cover Mapping Using Random Forests, GEOBIA, and NAIP Orthophotography: Findings and Recommendations. **Remote Sensing**, v. 11, n. 12, p. 1409, 13 jun. 2019.

MIRANDA, Rubens Augusto. **ARTIGO Clube dos 100 milhões: progresso técnico e a evolução da produção de milho no Brasil**. . [S.l: s.n.], 2019.

NASA. **MODIS - Moderate Resolution Imaging Spectroradiometer**. Disponível em: <https://modis.gsfc.nasa.gov/about/>. Acesso em: 15 jun. 2021.

NGULA NIIPELE, Johanna; CHEN, Jianping. The usefulness of alos-palsar dem data for drainage extraction in semi-arid environments in The Iishana sub-basin. **Journal of Hydrology: Regional Studies**, v. 21, n. December 2018, p. 57–67, 2019.

NRCAN. **Fundamentals of Remote Sensing**.

OLDONI, Lucas Volochen et al. LEM+ dataset: For agricultural remote sensing applications. **Data in Brief**, v. 33, p. 106553, 2020.

OLDONI, LUCAS VOLOCHEN. **MAPEAMENTO DE SOJA E MILHO COM MINERAÇÃO DE DADOS E IMAGENS SINTÉTICAS LANDSAT E MODIS**. 2018. 122 f. UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – CAMPUS DE CASCAVEL, 2018.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217–222, 22 jan. 2005a.

_____. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217–222, 22 jan. 2005b.

PELLETIER, Charlotte et al. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. **Remote Sensing of Environment**, v. 187, p. 156–168, 2016.

PEÑA-BARRAGÁN, José M. et al. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v. 115, n. 6, p. 1301–1316, jun. 2011.

VENANCIO, Luan et al. Potential of using spectral vegetation indices for corn green biomass estimation based on their relationship with the photosynthetic vegetation sub-pixel fraction. **Agricultural Water Management**, v. 236, n. April 2020, p. 106155, 2020. Disponível em: <https://doi.org/10.1016/j.agwat.2020.106155>.

PINO, Francisco Alberto. ESTIMAÇÃO SUBJETIVA DE SAFRAS AGRÍCOLAS. **IEA - Instituto de Economia Agrícola - Informações Econômicas, v.31, n.6**, p. 55–58, jun. 2001.

PLANET. **Our Constellation**. Disponível em: <https://storage.googleapis.com/planet-ditl/day-in-the-life/index.html>. Acesso em: 15 jun. 2021.

PLANETSCOPE. **Planet Plataform**. Disponível em: <https://www.planet.com/products/platform/>. Acesso em: 15 jun. 2021.

POORTINGA, Ate et al. Mapping sugarcane in Thailand using transfer learning, a lightweight convolutional neural network, NICFI high resolution satellite imagery and Google Earth Engine. **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 1, p. 100003, out. 2021.

PRATICÒ, Salvatore et al. Machine Learning Classification of Mediterranean Forest Habitats in Google Earth Engine Based on Seasonal Sentinel-2 Time-Series and Input Image Composition Optimisation. **Remote Sensing**, v. 13, n. 4, p. 586, 7 fev. 2021.

PRUDENTE, Victor Hugo Rohden et al. Limitations of cloud cover for optical remote sensing of agricultural areas across South America. **Remote Sensing Applications: Society and Environment**, v. 20, n. May, p. 100414, 2020.

QIN, Yi; MCVICAR, Tim R. Spectral band unification and inter-calibration of Himawari AHI with MODIS and VIIRS: Constructing virtual dual-view remote sensors from geostationary and low-Earth-orbiting sensors. **Remote Sensing of Environment**, v. 209, n. March, p. 540–550, 2018.

QU, Le'an et al. Accuracy Improvements to Pixel-Based and Object-Based LULC Classification with Auxiliary Datasets from Google Earth Engine. **Remote Sensing**, v. 13, n. 3, p. 453, 28 jan. 2021.

RAHMAN, Tabassum Yesmin et al. Automated oral squamous cell carcinoma identification using shape, texture and color features of whole image strips. **Tissue and Cell**, v. 63, n. December 2019, p. 101322, 2020.

REGE, Anushka; WARNEKAR, Smita Bodhankar; LEE, Janice Ser Huay. Mapping cashew monocultures in the Western Ghats using optical and radar imagery in Google Earth Engine. **Remote Sensing Applications: Society and Environment**, v. 28, p. 100861, nov. 2022.

RICHTER, Rudolf; KELLENBERGER, Tobias; KAUFMANN, Hermann. Comparison of Topographic Correction Methods. **Remote Sensing**, v. 1, n. 3, p. 184–196, 6 jul. 2009.

ROSSI, Fernando Saragosa et al. Identification of tillage for soybean crop by spectro-temporal variables, GEOBIA, and decision tree. **Remote Sensing Applications: Society and Environment**, v. 19, n. February, 2020a.

_____. Identification of tillage for soybean crop by spectro-temporal variables, GEOBIA, and decision tree. **Remote Sensing Applications: Society and Environment**, v. 19, p. 100356, ago. 2020b.

_____. Identification of tillage for soybean crop by spectro-temporal variables, GEOBIA, and decision tree. **Remote Sensing Applications: Society and Environment**, v. 19, n. February, p. 100356, ago. 2020c.

RUIZ, Luis Fernando Chimelo et al. Object-based classification of vegetation species in a subtropical wetland using Sentinel-1 and Sentinel-2A images. **Science of Remote Sensing**, v. 3, n. January, p. 100017, jun. 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2666017221000043>.

RYU, Jae-Hyun; OH, Dohyeok; CHO, Jaeil. Simple method for extracting the seasonal signals of photochemical reflectance index and normalized difference vegetation index measured using a spectral reflectance sensor. **Journal of Integrative Agriculture**, v. 20, n. 7, p. 1969–1986, 2021.

SARWAR, Abid et al. Mapping Groundwater Potential for Irrigation, by Geographical Information System and Remote Sensing Techniques: A Case Study of District Lower Dir, Pakistan. **Atmosphere**, v. 12, n. 6, p. 669, 24 maio 2021.

SCHULTZ, Bruno et al. Datasafra - Monitoramento de milho safrinha no Mato Grosso por sensoriamento remoto e Google Earth Engine. **XIX Simpósio Brasiliero de Sensoriamento Remoto**, p. 2933–2936, 2019a.

_____. Datasafra - Monitoramento de milho safrinha no Mato Grosso por sensoriamento remoto e Google Earth Engine. **XIX Simpósio Brasiliero de Sensoriamento Remoto**, p. 2933–2936, 2019b.

SENTINEL. **Sentinel Online**. Disponível em: <https://sentinel.esa.int/web/sentinel/thematic-areas/land-monitoring>. Acesso em: 15 jun. 2021.

SEYDI, Seyd Teymoor et al. Wildfire Damage Assessment over Australia Using Sentinel-2 Imagery and MODIS Land Cover Product within the Google Earth Engine Cloud Platform. **Remote Sensing**, v. 13, n. 2, p. 220, 10 jan. 2021.

SHEPHERD, J. D.; DYMOND, J. R. Correcting satellite imagery for the variance of reflectance and illumination with topography. **International Journal of Remote Sensing**, v. 24, n. 17, p. 3503–3514, 26 jan. 2003.

SHI, Yun et al. Framework of SAGI agriculture remote sensing and its perspectives in supporting national food security. **Journal of Integrative Agriculture**, v. 13, n. 7, p. 1443–1450, 2014.

SIDRA. **Levantamento Sistemático da Produção Agrícola - setembro 2020**. Disponível em: <https://sidra.ibge.gov.br/home/lspa/mato-grosso>. Acesso em: 25 jun. 2021.

SILVA, Carlos Antonio et al. Vegetation Indices for Discrimination of Soybean Areas: A New Approach. **Agronomy Journal**, v. 109, n. 4, p. 1331–1343, jul. 2017.

SILVA, CLESCY OLIVEIRA DA. **GEOPROCESSAMENTO APLICADO AO ZONEAMENTO AGRÍCOLA PARA CANA-DE-AÇÚCAR IRRIGADA DO ESTADO DO PIAU**. 2016. Faculdade de Ciências Agronômicas da UNESP, BOTUCATU – SP, 2016.

SILVA JUNIOR, Carlos Antonio. **Estimativa e discriminação de áreas de soja [Glycine max L .] no estado do Paraná com dados mono e multitemporais do sensor MODIS**. 2014. 181 f. Dissertação – UNIVERSIDADE ESTADUAL DE MARINGÁ, 2014. Disponível em: <http://www.pga.uem.br/uploads/carlos-antonio-da-silva-junior-dissertaaao-2.pdf_1412088000.pdf>.

SILVA JUNIOR, Carlos Antonio da et al. Object-based image analysis supported by data mining to discriminate large areas of soybean. **International Journal of Digital Earth**, v. 12, n. 3, p. 270–292, 4 mar. 2019a.

_____. Object-based image analysis supported by data mining to discriminate large areas of soybean. **International Journal of Digital Earth**, v. 12, n. 3, p. 270–292, 4 mar. 2019b.

_____. Simulating multispectral MSI bandsets (Sentinel-2) from hyperspectral observations via spectroradiometer for identifying soybean cultivars. **Remote Sensing Applications: Society and Environment**, v. 19, n. March, p. 100328, ago. 2020.

SOJAMAPS. **Plataformas GAAF/UNEMAT**. Disponível em: <https://pesquisa.unemat.br/gaaf/plataformas/>. Acesso em: 30 jun. 2021.

SPERANZA, Eduardo Antonio; GREGO, Célia Regina; GEBLER, Luciano. Analysis of pest incidence on apple trees validated by unsupervised machine learning algorithms. **Revista Engenharia na Agricultura - REVENG**, v. 30, p. 63–74, 27 abr. 2022.

STROMANN, Oliver et al. Dimensionality Reduction and Feature Selection for Object-Based Land Cover Classification based on Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine. **Remote Sensing**, v. 12, n. 1, p. 76, 24 dez. 2019.

SU, Tengfei; ZHANG, Shengwei. Local and global evaluation for remote sensing image segmentation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 256–276, 2017.

SULLIVAN, Brian. **NICFI's satellite imagery of the global tropics now available in Earth Engine for analysis**. Disponível em: <https://medium.com/google-earth/nicfis-satellite-imagery-of-the-global-tropics-now-available-in-earth-engine-for-analysis-1016df52a63d>. Acesso em: 30 nov. 2022.

SUN, Deyong et al. Using Landsat 8 OLI data to differentiate Sargassum and Ulva prolifera blooms in the South Yellow Sea. **International Journal of Applied Earth Observation and Geoinformation**, v. 98, p. 102302, 2021.

SUN, Genyun et al. Combinational shadow index for building shadow extraction in urban areas from Sentinel-2A MSI imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. December 2018, p. 53–65, 2019.

O'SHEA, Tara. **NICFI Tropical Forest Basemaps Now Available In Google Earth Engine**. Disponível em: <https://www.planet.com/pulse/nicfi-tropical-forest-basemaps-now-available-in-google-earth-engine/>. Acesso em: 30 nov. 2022.

TASSI, Andrea et al. Pixel- vs. Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest: The Case Study of Maiella National Park. **Remote Sensing**, v. 13, n. 12, p. 2299, 11 jun. 2021a.

_____. Pixel- vs. Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest: The Case Study of Maiella National Park. **Remote Sensing**, v. 13, n. 12, p. 2299, 11 jun. 2021b.

TASSI, Andrea; VIZZARI, Marco. Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms. **Remote Sensing**, v. 12, n. 22, p. 3776, 17 nov. 2020.

TETTEH, Gideon Okpoti; GOCHT, Alexander; CONRAD, Christopher. Optimal parameters for delineating agricultural parcels from satellite images based on supervised Bayesian optimization. **Computers and Electronics in Agriculture**, v. 178, n. April, p. 105696, 2020.

THENKABAIL, Prasad; LYON, John; HUETE, Alfredo. **Advanced Applications in Remote Sensing of Agricultural Crops and Natural Vegetation**. [S.l.]: CRC Press, 2018.

UNAL CILEK, Muge; CILEK, Ahmet. Analyses of land surface temperature (LST) variability among local climate zones (LCZs) comparing Landsat-8 and ENVI-met model data. **Sustainable Cities and Society**, v. 69, n. March, p. 102877, jun. 2021.

UPADHYAY, Vipin et al. Revisit and optimisation of spectral data collection techniques from vegetation using handheld non-imaging spectroscopic sensor for minimising errors. **Vibrational Spectroscopy**, v. 111, n. May, p. 103159, 2020.

VIZZARI, Marco. PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. **Remote Sensing**, v. 14, n. 11, p. 2628, 31 maio 2022a.

_____. PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. **Remote Sensing**, v. 14, n. 11, p. 2628, 31 maio 2022b.

WAGNER, Marcus Vinicius et al. Avaliação do ciclo fenológico da cultura do milho em função da soma térmica em Guarapuava, Sul do Brasil. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias,** v. 4, n. 1, p. 135–149, 30 abr. 2011.

WANG, Lili et al. Assessment and comparison of three years of Terra and Aqua MODIS Aerosol Optical Depth Retrieval (C005) in Chinese terrestrial regions. **Atmospheric Research**, v. 97, n. 1–2, p. 229–240, 2010.

WANG, Qunming et al. Filling gaps in Landsat ETM+ SLC-off images with Sentinel-2 MSI images. **International Journal of Applied Earth Observation and Geoinformation**, v. 101, n. November 2020, p. 102365, set. 2021a.

_____. Filling gaps in Landsat ETM+ SLC-off images with Sentinel-2 MSI images. **International Journal of Applied Earth Observation and Geoinformation**, v. 101, n. November 2020, p. 102365, 2021b. Disponível em: <https://doi.org/10.1016/j.jag.2021.102365>.

WANG, Xiaona et al. Object-based spectral-phenological features for mapping invasive Spartina alterniflora. **International Journal of Applied Earth Observation and Geoinformation**, v. 101, p. 102349, 2021.

WEISMANN, Martin. Fases de desenvolvimento da cultura do milho. **Tecnologia e Produção: Milho Safrinha e Culturas de Inverno**, p. 31–38, 2008.

WESSELS, Konrad J. et al. Rapid land cover map updates using change detection and robust random forest classifiers. **Remote Sensing**, v. 8, n. 11, p. 1–24, 2016.

WIJESINGHA, Jayan et al. Comparison of Spaceborne and UAV-Borne Remote Sensing Spectral Data for Estimating Monsoon Crop Vegetation Parameters. **Sensors**, v. 21, n. 8, p. 2886, 20 abr. 2021.

WU, Bingfang; LI, Qiangzi. Crop planting and type proportion method for crop acreage estimation of complex agricultural landscapes. **International Journal of Applied Earth Observation and Geoinformation**, v. 16, n. 1, p. 101–112, 2012.

XIONG, Jun et al. Nominal 30-m Cropland Extent Map of Continental Africa by Integrating Pixel-Based and Object-Based Algorithms Using Sentinel-2 and Landsat-8 Data on Google Earth Engine. **Remote Sensing**, v. 9, n. 10, p. 1065, 19 out. 2017.

XU, Ru. Mapping rural settlements from landsat and sentinel time series by integrating pixel-and object-based methods. **Land**, v. 10, n. 3, p. 1–18, 2021.

YU, Zhiqi et al. Fishpond mapping by spectral and spatial-based filtering on google earth engine: A case study in singra upazila of Bangladesh. **Remote Sensing**, v. 12, n. 17, 2020.

YUAN, Linan; LIAO, Jingjuan. Parametric Design of a Microwave Radiometer for Land Surface Temperature Retrieval from Moon-Based Earth Observation Platform.

Remote Sensing, v. 12, n. 24, p. 4110, 16 dez. 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/24/4110>.

YUAN, Ningge et al. UAV Remote Sensing Estimation of Rice Yield Based on Adaptive Spectral Endmembers and Bilinear Mixing Model. **Remote Sensing**, v. 13, n. 11, p. 2190, 4 jun. 2021.

ZANOTTA, Daniel Capella; ZORTEA, Maciel; FERREIRA, Matheus Pinheiro. A supervised approach for simultaneous segmentation and classification of remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 142, n. April, p. 162–173, 2018.

ZHANG, Chunhua et al. Object-oriented Classification of Land Cover Based on Landsat 8 OLI Image Data in the Kunyu Mountain. **SCIENTIA GEOGRAPHICA SINICA**, p. 1904–1913, 2018.

ZHENG, Yang et al. Maize and weed classification using color indices with support vector data description in outdoor fields. **Computers and Electronics in Agriculture**, v. 141, p. 215–222, 2017.