



UNIVERSIDADE ESTADUAL PAULISTA
"CAMPUS DE RIO CLARO"
INSTITUTO DE GEOCIÊNCIAS E CIÊNCIAS EXATAS
Programa de Pós Graduação em Geografia



UNIVERSIDADE ESTADUAL PAULISTA
"Júlio de Mesquita Filho"
Instituto de Geociências e Ciências Exatas Câmpus
de Rio Claro

EDVALDO GUEDES JÚNIOR

**SÉRIES TEMPORAIS DE IMAGENS DE SENSORIAMENTO
REMOTO APLICADAS AO ESTUDO DE ÁREAS DE CULTIVO
AGRÍCOLA: CONTRIBUIÇÃO METODOLÓGICA PARA ANÁLISE
DO USO DA TERRA**

Tese de Doutorado apresentada ao Instituto de Geociências e Ciências Exatas do Câmpus de Rio Claro, da Universidade Estadual Paulista "Júlio de Mesquita Filho", como parte dos requisitos para obtenção do título de Doutor em Geografia.

Orientador: Prof. Dr. Sergio dos Anjos Ferreira Pinto

Rio Claro - SP

2021

EDVALDO GUEDES JÚNIOR

**SÉRIES TEMPORAIS DE IMAGENS DE SENSORIAMENTO
REMOTO APLICADAS AO ESTUDO DE ÁREAS DE CULTIVO
AGRÍCOLA: CONTRIBUIÇÃO METODOLÓGICA PARA ANÁLISE
DO USO DA TERRA**

Tese de Doutorado apresentada ao Instituto de Geociências e Ciências Exatas do Câmpus de Rio Claro, da Universidade Estadual Paulista “Júlio de Mesquita Filho”, como parte dos requisitos para obtenção do título de Doutor em Geografia.

Orientador: Prof. Dr. Sergio dos Anjos Ferreira Pinto

Rio Claro - SP

2021

G924s

Guedes Junior, Edvaldo

Séries temporais de imagens de Sensoriamento Remoto aplicados à identificação de culturas agrícolas : contribuição metodológica para análise do uso e cobertura da terra / Edvaldo Guedes Junior. -- Rio Claro, 2021

102 p. : il., tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Instituto de Geociências e Ciências Exatas, Rio Claro

Orientador: Sergio dos Anjos Ferreira Pinto

1. Uso e Cobertura da Terra. 2. Sensoriamento Remoto. 3. Geoprocessamento. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Geociências e Ciências Exatas, Rio Claro. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

EDVALDO GUEDES JÚNIOR

**SÉRIES TEMPORAIS DE IMAGENS DE SENSORIAMENTO
REMOTO APLICADAS AO ESTUDO DE ÁREAS DE CULTIVO
AGRÍCOLA: CONTRIBUIÇÃO METODOLÓGICA PARA ANÁLISE
DO USO DA TERRA**

Tese de Doutorado apresentada ao Instituto de Geociências e Ciências Exatas do Câmpus de Rio Claro, da Universidade Estadual Paulista “Júlio de Mesquita Filho”, como parte dos requisitos para obtenção do título de Doutor em Geografia.

Comissão Examinadora

Prof. Dr. Sergio dos Anjos Ferreira Pinto (IGCE/UNESP/Rio Claro)

Prof. Dr. Sergio Luis Antonello (IGCE/UNESP/Rio Claro)

Profa. Dra. Andreia Medinilha Pancher (IGCE/UNESP/Rio Claro)

Prof. Dr. Luis Henrique Pereira (IDgeo/Piracicaba)

Prof. Dr. Pedro Augusto Breda Fontão (CT/UFPR/Curitiba)

CONCEITO: APROVADO

Rio Claro, 1 de dezembro de 2021

AGRADECIMENTOS

O presente trabalho foi realizado com apoio do Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), que contribuíram integralmente para o desenvolvimento desta pesquisa.

Agradeço a Deus e a minha família, em especial meus pais Edvaldo e Vera; irmãos André, Davi e Larissa; e meus avós Laerte (*in memoriam*) e Elisa. Vocês são a minha maior motivação. Agradeço ao meu orientador Prof. Dr. Sergio dos Anjos. Me sinto privilegiado pelos anos que pude conviver a aprender com o professor Sergio. Agradeço ao meu orientador de mestrado professor Dr. Fabiano Tomazini da Conceição, e ao professor Dr. Alexandre Martins Fernandes. Obrigado por terem sempre me ajudado com seus valorosos conselhos. Agradeço ao meu amigo professor Dr. Luiz Henrique Pereira, que durante minha graduação me ensinou tudo o que pode sobre geoprocessamento. Sua amizade, ajuda e compreensão me serviram de suporte nos momentos difíceis deste doutorado.

Agradeço ao Programa de Pós Graduação em Geografia do Instituto de Geociências e Ciências Exatas e UNESP por todo apoio e suporte fornecido durante a Pandemia de Covid 19. Agradeço aos queridos Técnicos Administrativos do Departamento de Geografia e Planejamento, em especial a Magali, ao amigo Ubirajara (Bira). Agradeço a toda equipe de profissionais da Unesp de Rio Claro.

SÉRIES TEMPORAIS DE IMAGENS DE SENSORIAMENTO REMOTO APLICADOS À IDENTIFICAÇÃO DE CULTURAS AGRÍCOLAS: CONTRIBUIÇÃO METODOLÓGICA PARA ANÁLISE DO USO E COBERTURA DA TERRA

Resumo

O estudo do uso e cobertura da terra é importante para o entendimento dos sistemas terrestres e da dinâmica geográfica resultante da interação entre o homem e a natureza. Como resultado desta interação, observamos padrões de uso e cobertura da terra como áreas agrícolas, florestas e centros urbanos que configuram as paisagens terrestres, de forma que nestes recortes geográficos ocorrem as complexas relações de troca entre matéria e energia que sustentam a vida na Terra. Como contribuição para o entendimento dos padrões de uso e cobertura da terra, esta pesquisa utilizou técnicas de classificação supervisionada e extração de índice de vegetação em séries temporais de imagens dos sistemas orbitais LANDSAT e SENTINEL-2 para avaliar a dinâmica do uso e cobertura da terra na região centro leste do Estado de São Paulo. As imagens dos sistemas orbitais foram processadas a partir do sistema de geoprocessamento na nuvem “*Google Earth Engine*” (GEE), sendo geradas as classes de uso e cobertura da terra compostas por áreas urbanas, vegetação natural, pastagens, lavouras de ciclo anual, lavouras de ciclo perene, solo exposto e corpos d’ água. O processo de classificação das imagens orbitais teve frequência mensal abrangendo o período de janeiro a dezembro de 2020 e foi estatisticamente validado através do índice kappa, matriz de confusão e pelos índices de acurácia do produtor e consumidor. Os resultados do processo de classificação do uso da terra permitiram observar uma dinâmica espacial dominada por culturas agrícolas de ciclo anual, onde a cana-de-açúcar é a cultura dominante, exercendo grande influência no aspecto ambiental da área de estudo.

Palavras chave: Uso e Cobertura da Terra, Sensoriamento Remoto, Geoprocessamento.

TIME SERIES OF REMOTE SENSING IMAGES APPLIED TO THE IDENTIFICATION OF AGRICULTURAL CROPS: METHODOLOGICAL CONTRIBUTION TO ANALYSIS OF LAND USE AND COVERAGE

Abstract

The study of land use and land cover is important for the understanding of land systems and the geographic dynamics resulting from the interaction between man and nature. As a result of this interaction, we observe patterns of land use and land cover such as agricultural areas, forests and urban centers that configure terrestrial landscapes, where take a place the complex relations exchange between matter and energy that sustain life on Earth. As a contribution to understand land use and land cover patterns, this research used supervised classification techniques and vegetation index extract by time series images from the LANDSAT and SENTINEL-2 orbital systems to assess the dynamics of land use and land cover in the central eastern region of the São Paulo State. The images of the orbital systems were processed using the “Google Earth Engine” (GEE) cloud geoprocessing system, generating land use and land cover classes composed of urban areas, natural vegetation, pastures, annual crops, perennial crops, bare soil and water. The classification process of orbital images had a monthly frequency covering the period from January to December 2020 and was statistically validated through the kappa index, confusion matrix and the producer and consumer accuracy indices. The results of the land use classification allowed us to observe a spatial dynamic dominated by annual crops, where sugarcane is the dominant crop with great influence on environmental aspect of the study area.

Key words: Land Use, Land Cover, Remote Sensing, Geographic Information Systems.

LISTA DE FIGURAS

Figura 1: Variação de classes de cobertura da terra no Brasil entre 1985 e 2015.	16
Figura 2: Distribuição espacial de imagens LANSAT arquivadas no USGS até jan/2015	32
Figura 3: Fluxograma metodológico.	36
Figura 4: Características espectrais dos sensores OLI e MSI.....	39
Figura 5: Application Programming Interface (API) – entrada e visualização de dados no GEE.	47
Figura 6: Localização da área de estudo.....	51
Figura 7: Comparação da imagem do sensor OLI e classificação supervisionada - jan. 2020. ..	59
Figura 8: Comparação da imagem do sensor OLI e classificação supervisionada - fev. 2020. ..	60
Figura 9: Comparação da imagem do sensor OLI e classificação supervisionada - mar. 2020. .	61
Figura 10: Comparação da imagem do sensor OLI e classificação supervisionada - abr. 2020. 62	
Figura 11: Comparação da imagem do sensor OLI e classificação supervisionada - mai. 2020. ..	63
Figura 12: Comparação da imagem do sensor OLI e classificação supervisionada - jun. 2020. 64	
Figura 13: Comparação da imagem do sensor OLI e classificação supervisionada - jul. 2020. .	65
Figura 14: Comparação da imagem do sensor OLI e classificação supervisionada - ago. 2020. 66	
Figura 15: Comparação da imagem do sensor OLI e classificação supervisionada - set. 2020. .	67
Figura 16: Comparação da imagem do sensor OLI e classificação supervisionada - out. 2020. 68	
Figura 17: Comparação da imagem do sensor OLI e classificação supervisionada - nov. 2020. 69	
Figura 18: Comparação da imagem do sensor OLI e classificação supervisionada - dez. 2020. .	70
Figura 19: Comparação da imagem do sensor MSI e classificação supervisionada - jan. 2020. 72	
Figura 20: Comparação da imagem do sensor MSI e classificação supervisionada - fev. 2020. 73	
Figura 21: Comparação da imagem do sensor MSI e classificação supervisionada - mar. 2020.74	
Figura 22: Comparação da imagem do sensor MSI e classificação supervisionada - abr. 2020. 75	
Figura 23: Comparação da imagem do sensor MSI e classificação supervisionada - mai. 2020.76	
Figura 24: Comparação da imagem do sensor MSI e classificação supervisionada - jun. 2020. 77	
Figura 25: Comparação da imagem do sensor MSI e classificação supervisionada - jul. 2020. .	78
Figura 26: Comparação da imagem do sensor MSI e classificação supervisionada - ago. 2020.79	
Figura 27: Comparação da imagem do sensor MSI e classificação supervisionada - set. 2020. 80	
Figura 28: Comparação da imagem do sensor MSI e classificação supervisionada - out. 2020. 81	

Figura 29: Comparação da imagem do sensor MSI e classificação supervisionada - nov. 2020.	82
Figura 30: Comparação da imagem do sensor MSI e classificação supervisionada - dez. 2020.	83
Figura 31: Cultivos identificados em campo	85
Figura 32: Índice NDVI estágios iniciais do milho	86
Figura 33: índice NDVI estágios iniciais da cana-de açúcar.....	87
Figura 34: Índice NDVI - cultivo de café.....	88
Figura 35: Índice NDVI – cultivo de café nos estágios iniciais	89
Figura 38: Índice NDVI algodão em estágio pré-colheita.....	90
Figura 39: Cultivo de milho com presença de ervas daninhas	91
Figura 40: Índice NDVI do trigo em estágio pré-colheita.....	92
Figura 41: Índice NDVI cultivo de girassol	93
Figura 42: Índice NDVI de cultivo de sorgo	94
Figura 44: índice NDVI de cultivo de trigo.....	95

LISTA DE GRÁFICOS

Gráfico 1 - Precipitação média mensal - Posto D4-036 Graúna.....	52
Gráfico 2 - Precipitação média mensal - Posto D4-074 Ipeúna.....	53
Gráfico 3 - Temperatura máxima - média mensal (°C).....	53
Gráfico 4 - Temperatura mínima - média mensal (°C).....	54
Gráfico 5 - Umidade relativa do ar - média mensal (%).....	55

LISTA DE TABELAS

Tabela 1 - Evolução das ferramentas de análise espacial.	33
Tabela 2 – Características dos sensores OLI e MSI.....	39
Tabela 3 - Características do sensor OLI.....	41
Tabela 4 - Características do sensor MSI.....	43
Tabela 5 - Principais dados disponíveis nas bibliotecas do Google Earth Engine	44

LISTA DE ABREVIATURAS

API	Application Programming Interface
CEAPLA	Centro de Análise e Planejamento Ambiental – UNESP/RC
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
DAEE	Departamento de Águas e Energia Elétrica do Estado de São Paulo
DGI-INPE	Divisão de Geração de Imagens – Instituto Nacional de Pesquisas Espaciais
EROS	Earth Resources Observation and Science
ESA	European Space Agency – Agência Espacial Europeia
ESRI	Environmental Systems Research Institute
EVI	Índice de Vegetação Realçado
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	Painel Intergovernamental Sobre Mudanças Climáticas
IPT	Instituto de Pesquisas Tecnológicas
IRS	Indian Remote Sensing Satellite
FAO	Organização das Nações Unidas para a Alimentação e Agricultura
GEE	Google Earth Engine
GOES	Geostationary Operational Environmental Satellite
LANDSAT	Land Resource Satellite
LaSRC	Land Surface Reflectance Code
Ma	Milhões de anos
Mha	Milhões de hectares
MODIS	Moderate Resolution Spectroradiometer
MSI	Multispectral Instrument
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared (Infravermelho próximo)
NASA	National Aeronautics and Space Administration
NOOA	National Oceanic and Atmospheric Administration
OLCI	Ocean and Land Colour Instrument
OLI	Object Land Imager
SAR	Synthetic Aperture Radar – Radar de Abertura Sintética
SIG	Sistema de Informação Geográfica
S-NPP	Suomi National Polar-orbiting Partnership
SWIR	Short Wave Infrared (Infravermelho de Ondas Curtas)
TIRS	Thermal Infrared Sensor
USDA	Departamento de Agricultura do Estados Unidos da América
USGS	Serviço Geológico dos Estados Unidos da América
VLS	Veículo lançador de satélites

SUMÁRIO

1. INTRODUÇÃO E JUSTIFICATIVA	14
2. OBJETIVOS E PREMISSAS DA PESQUISA.....	19
3. REVISÃO BIBLIOGRÁFICA	21
3.1 Uso e cobertura da terra e mudanças ambientais	23
3.2 Uso e cobertura da terra e sua relação com as atividades agrícolas.....	27
3.3 Geotecnologias aplicadas ao ensino e análise geográfica	32
4. MATERIAIS E MÉTODOS.....	36
4.1 Sistemas Sensores de média resolução espacial.....	38
4.2 Sistema LANDSAT 8.....	40
4.3 Sistema SENTINEL-2.....	42
4.4 Google Earth Engine	43
4.5 Classificação supervisionada através do algoritmo Random Forest	47
4.6 Testes de validação do mapeamento	48
4.7 Índice NDVI.....	49
4.8 Trabalho de campo	50
5. ÁREA DE ESTUDO	50
6. RESULTADOS E DISCUSSÃO.....	58
6.1 Classificação supervisionada de imagens do sensor OLI – janeiro 2020.	58
6.2 Classificação supervisionada de imagens do sensor OLI – fevereiro 2020.	59
6.3 Classificação supervisionada de imagens do sensor OLI – março 2020.....	60
6.4 Classificação supervisionada de imagens do sensor OLI – abril 2020.	61
6.5 Classificação supervisionada de imagens do sensor OLI – maio 2020.....	62
6.6 Classificação supervisionada de imagens do sensor OLI – junho 2020.	63
6.7 Classificação supervisionada de imagens do sensor OLI – julho 2020.	64
6.8 Classificação supervisionada de imagens do sensor OLI – agosto 2020.	65
6.9 Classificação supervisionada de imagens do sensor OLI – setembro 2020.....	66
6.10 Classificação supervisionada de imagens do sensor OLI – outubro 2020.	68
6.11 Classificação supervisionada de imagens do sensor OLI – novembro 2020.	69
6.12 Classificação supervisionada de imagens do sensor OLI – dezembro 2020.....	70
6.13 Resultados da classificação de imagens do sensor MSI – janeiro 2020.....	71

6.14 Resultados da classificação de imagens do sensor MSI – fevereiro 2020.	72
6.15 Resultados da classificação de imagens do sensor MSI – março 2020.....	73
6.16 Resultados da classificação de imagens do sensor MSI – abril 2020.	74
6.17 Resultados da classificação de imagens do sensor MSI – maio 2020.....	76
6.18 Resultados da classificação de imagens do sensor MSI – junho 2020.....	77
6.19 Resultados da classificação de imagens do sensor MSI – julho 2020.	78
6.20 Resultados da classificação de imagens do sensor MSI – agosto 2020.	78
6.21 Resultados da classificação de imagens do sensor MSI –setembro 2020.....	80
6.22 Resultados da classificação de imagens do sensor MSI – outubro 2020.	81
6.23 Resultados da classificação de imagens do sensor MSI – novembro 2020.	82
6.24 Resultados da classificação de imagens do sensor MSI – dezembro 2020.....	83
6.25 Trabalho de Campo	84

1. INTRODUÇÃO E JUSTIFICATIVA

Dentre os eixos temáticos que constituem a formação e evolução da Geografia como ciência, podemos observar a contribuição das ciências naturais, contextualizada sob a ótica dos geossistemas e, de igual modo, uma grande influência e contribuição das linhas de pensamento ligadas às ciências humanas com ênfase nos fenômenos sociais e históricos que direcionam as diversas configurações do espaço geográfico. Neste contexto, a partir da intersecção entre as ciências naturais e humanas, Ross (2019, p. 15) situa como objeto máximo de preocupação da Geografia como sendo as relações entre o homem e a natureza, que se processam de forma complexa ao longo do tempo e sobre o espaço. Essas relações ocorrem em um lapso espaço temporal que constitui o palco onde as sociedades se organizam, se desenvolvem e promovem as mudanças na biosfera terrestre. A partir deste cenário, o conceito de uso e cobertura da terra surge como uma variável de dimensões significativas no contexto das relações entre o homem e a natureza, uma vez que o uso e cobertura da terra tem relação com todas as atividades humanas, dentre elas a exploração dos recursos naturais para atender as demandas das sociedades, instaurando o processo de apropriação da natureza e seus recursos e gerando os impactos ambientais que alteram os fluxos de matéria e energia dos geossistemas.

De acordo com Christofolletti (1993, p.21), os geossistemas constituem uma organização espacial resultante da interação entre os elementos físicos e biológicos como o clima, o ciclo hidrológico, a vegetação, a cobertura da terra, entre outros fatores que fazem com que esta organização espacial se ajuste aos fluxos de matéria e energia que circulam no ambiente. Conforme o IPCC (Intergovernmental Panel on Climate Change, 2019), muitas das atividades humanas que são expressas através do uso e cobertura da terra, têm provocado modificações no meio ambiente. Essas mudanças ambientais são decorrentes principalmente da supressão de florestas para instauração de lavouras, pastagens e centros urbanos; e da poluição atmosférica, decorrente da queima de combustíveis fósseis. Conforme Eyring *et al.* (2021, p.12), estes cenários decorrentes das ações humanas possuem a capacidade de alterar os fluxos de matéria e energia dos ecossistemas globais, constituindo desta forma o presente cenário das crises ambientais e mudanças climáticas que afetam as sociedades e o equilíbrio de toda Terra.

Considerando que os padrões de uso e cobertura da terra geram configurações espaciais capazes de alterar os fluxos de matéria e energia que dão suporte para os ecossistemas globais,

observa-se um crescente aumento na frequência com que ocorrem eventos climáticos extremos, de forma que hoje é aceita a correlação entre o aumento dos eventos climáticos extremos e as ações humanas sobre a superfície terrestre (IPCC, 2019, p. 74). O aumento dos eventos climáticos extremos, causadores de perdas materiais e humanas, podem ser potencializados pela remoção e alteração da cobertura vegetal natural, pelo crescimento das áreas urbanas, pelas atividades de garimpo e exploração de recursos contidos no subsolo, em função do aumento das áreas destinadas a produção de proteínas, fibras e insumos industriais. Essas atividades, produtoras de passivos e externalidades ambientais, condizem com categorias de uso e cobertura da terra que conduzem à degradação e perda de sustentabilidade dos ecossistemas.

Neste sentido, podemos afirmar que o planejamento e gestão do uso e cobertura da terra é de fundamental importância para manutenção da sustentabilidade e preservação dos sistemas terrestres, constituindo um elemento sobre o qual vários segmentos das ciências têm dedicado esforços. De acordo com a FAO (Organização das Nações Unidas para a Alimentação e Agricultura, 2002, p. 57), podemos elencar quatro principais macro categorias de uso e cobertura da terra:

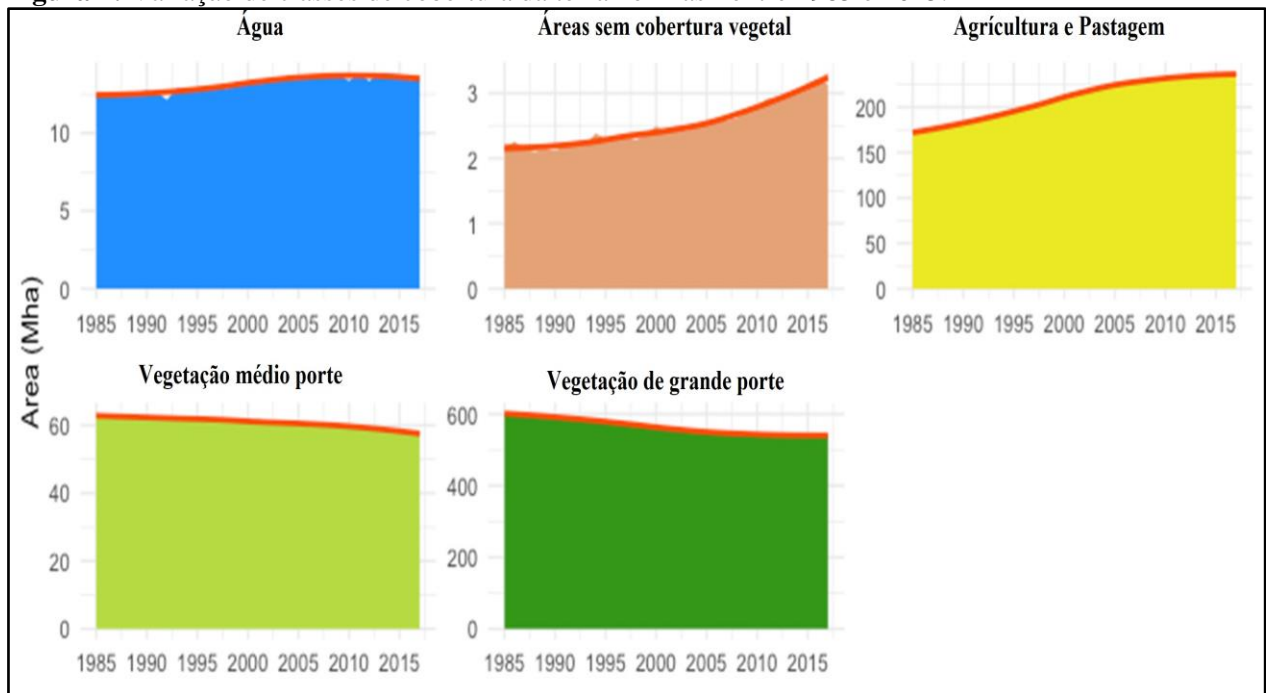
- a) Uso Urbano, relacionado com toda infra estrutura das cidades e obras de construção civil;
- b) Uso agrícola, que diz respeito as áreas destinadas ao cultivo de culturas agrícolas, pastagens ou qualquer atividade de caráter agropecuário;
- c) Áreas de cobertura vegetal natural, constituídas por fito biomas sazonalmente distribuídos. Exemplos esta macro categoria são as florestas tropicais úmidas situadas na região equatorial, e as Savanas na faixa tropical do hemisfério sul;
- d) Áreas inóspitas para ocupação humana, como os cinturões orogênicos, desertos e regiões polares.

Estas categorias de uso e cobertura da terra caracterizam sistemas ambientais que podem apresentar-se, em sua maior parte ainda preservados, mas com uma crescente influência humana, a exemplo do bioma Amazônico descrito por Ab'Saber (2003); e ambientes que perderam toda sua cobertura natural, tendo como exemplo a configuração espacial dos grandes centros urbanos descritos por Santos (1993).

Dentre as categorias de uso e cobertura da terra, Loveland (2012, p. 14) observa que as atividades com maior potencial de gerar externalidades negativas para os sistemas terrestres estão ligadas a setores relevantes da econômica, como a mineração e as atividades agropecuárias.

Especificamente, em se tratando da parcela de uso e cobertura da terra ocupada por atividades agropecuárias, Hooke *et al.* (2012, p. 73) afirmam que tais atividades ocupam quase metade da área da superfície terrestre, tendo um peso relevante no conjunto de atividades de uso e cobertura da terra e na alteração dos ecossistemas. Conforme Souza *et al.* (2020, p. 2), a porção do território brasileiro ocupado pelas atividades agropecuárias teve um expressivo aumento em detrimento de áreas de cobertura natural. Segundo o autor, no período entre 1985 e 2015 foi constatado um aumento de 46% nas áreas de pastagens e 172% nas áreas ocupadas pelas atividades agrícolas. Em contrapartida, a área ocupada por vegetação natural foi reduzida em 71 Mha (Milhões de hectares). A Figura 1 resume as variações na cobertura de terra, destacando o aumento das áreas ocupadas por agricultura e pastagem, e o declínio das áreas ocupadas por formações vegetais de médio e grande porte que ocorreram no território brasileiro no período que se estende de 1985 até 2015.

Figura 1: Variação de classes de cobertura da terra no Brasil entre 1985 e 2015.



FONTE: Modificado de SOUZA et al. 2020.

Tendo em vista as mudanças no uso e cobertura da terra, são necessários estudos para a compreensão das mudanças em suas configurações espaciais, tendo por objetivo atenuar os cenários de mudanças ambientais. Neste sentido, o processamento de séries temporais de imagens digitais, feitas a partir de sensores a bordo de plataformas orbitais, possui a capacidade de retratar de forma ampla as variações na matéria (vegetação, solos, rochas e água) que compõe cobertura da

superfície terrestre ao longo do tempo e em amplas escalas que variam do local ao global. Neste sentido, muitos aspectos da interação entre as sociedades e a natureza podem ser estudados através do uso de séries temporais de imagens de sensoriamento remoto, que retratam os padrões de uso e cobertura da terra, sendo aplicadas em pesquisas de diversas áreas do conhecimento. Yang *et al.* (2021) e Lu *et al.* (2019) utilizaram séries temporais de imagens de sensoriamento remoto foram aplicadas no estudo de processos que ocorrem nos centros urbanos, relacionando índices de cobertura vegetal com índices de qualidade de vida em cidades médias na China. Bayad *et al.* (2020) utilizaram séries temporais de sensoriamento remoto para estudar cenários de déficit hídrico em regiões de pastagens na Nova Zelândia. Arabi *et al.* (2018) aplicaram séries temporais de imagens de sensoriamento remoto na caracterização físico-químicas das águas do Mar de Wadden na Holanda. No Brasil, Pinto (1996) utilizou técnicas de sensoriamento remoto, geoprocessamento e modelagem ambiental para estudar processos erosivos.

Chistofolletti (1999, p. 231) considera que a organização espacial dos sistemas ambientais, representa uma visão abrangente da natureza, segundo uma perspectiva geográfica. Neste sentido, considerando a perspectiva de análise da Geografia Física, os sistemas ambientais de uso e cobertura da terra, podem ser pesquisados a partir de uma abordagem integradora de suas correlações com os elementos do meio físico, representados pelos alvos de sensoriamento remoto (vegetação, solos, rochas, água, atmosfera) registrados nas séries temporais.

Os dados registros nas séries temporais de sensoriamento são estudados com o auxílio de ferramentas de geoprocessamento que permitem a manipulação e interpretação de dados necessários para o mapeamento do uso e cobertura da terra. Tais procedimentos metodológicos se apoiam no conceito de inteligência geográfica, que está relacionado com as aplicações das tecnologias locacionais na resolução de problemas diários (LONGLEY *et al.*, 2012). Neste sentido, a inteligência geográfica, através de seu conjunto conceitual, fornece as ferramentas e métodos necessários para auxiliar na resolução de problemas decorrentes do mal uso dos recursos naturais. Para este afim, utiliza-se os produtos cartográficos, obtidos através de imagens de sistemas orbitais e séries temporais que permitem a gestão eficiente do uso e cobertura da terra.

Neste sentido, considerando os argumentos exposto concernentes à ciência da informação geográfica, esta pesquisa teve por objetivo o desenvolvimento e aplicação de proposta metodológica para o mapeamento do uso e da cobertura e da terra com ênfase no uso agrícola, sendo desenvolvida com o auxílio de tecnologias de geoprocessamento em nuvem, arquitetadas na

plataforma computacional Google Earth Engine (GEE). O mapeamento de uso e cobertura da terra foi realizado através de técnicas de geoprocessamento voltadas à classificação de produtos de sensoriamento remoto obtidos pelo satélite de recurso terrestre LANDSAT 8 (Land Resources Satellite), que carrega a bordo os sensores OLI (Operational Land Imager) e TIRS (Thermal Infrared Sensor); e pelo satélite de recursos terrestres SENTINEL-2, que opera o sensor MSI (Multispectral Instrument). Os dados obtidos a partir da série histórica de 2000 foram processados por algoritmos de classificação supervisionada pixel a pixel, e de classificação não supervisionada orientada a objeto, presentes como funções de análise de dados no ambiente de programação do Google Earth Engine. Essas tecnologias direcionadas pelos procedimentos metodológicos adotados por essa pesquisa podem fornecer soluções para minimizar os impactos causados pelas atividades relacionadas com o uso da terra, servindo como material didático direcionado ao ensino em nível de graduação.

2. OBJETIVOS E PREMISSAS DA PESQUISA

O objetivo desta pesquisa consiste em avaliar o uso e cobertura da terra registradas em séries temporais de imagens de sensoriamento remoto, buscando identificar as áreas de uso e cobertura agrícola, com o auxílio de Sistemas de Informações Geográficas (SIG's). O estudo do uso e cobertura da terra se pautara na programação e execução de algoritmos de classificação de imagens, estruturados na arquitetura computacional dos servidores do Google. As análises das imagens de sensoriamento remoto foram feitas a partir de procedimento metodológico que explora a plataforma de geoprocessamento na nuvem Google Earth Engine que permite aplicar os algoritmos de classificação na estrutura matricial das imagens do sensor Object Land Imager (OLI), a bordo do satélite de recursos terrestres LANDSAT 8; e do sensor Multispectral Instrument (MSI), a bordo do satélite de recursos terrestres SENTINEL-2.

As premissas de uma pesquisa são ocasiões, eventos ou circunstâncias que balizam o desenvolvimento de um estudo e direcionam seus possíveis resultados. Tomando esta ideia como base, esta pesquisa partiu das seguintes premissas:

- a) O perfil temporal da distribuição dos valores de índices espectrais registrados em imagens multiespectrais de sensores orbitais, expressam a curva de variação de um alvo ao longo do tempo e no espaço;
- b) A dinâmica temporal de reflectância dos alvos variam sazonalmente, podendo se estabelecer padrões em função da época do ano e tempo de duração de incidência de radiação solar, que influencia nas características da cobertura da terra, principalmente no que diz respeito à cobertura vegetal.

Assim, assume-se como premissa de pesquisa que as curvas espectrais, obtidas a partir de séries temporais de dados de sensoriamento remoto, constituem um critério para discriminação e identificação de diferentes alvos terrestres, sendo estabelecidas as classes de uso que classificaram os alvos em função da variação de suas características espectrais. Alvos como solo e vegetação possuem assinaturas espectrais muito distintas, sendo desta forma classificadas sem dificuldades. Alvos dentro de uma mesma macro classe, como diferentes tipos de vegetação, possuem assinaturas espectrais muito semelhantes, sendo necessário utilizar critérios que levam em consideração a variação temporal nos níveis de reflectância de determinada espécie vegetal. Neste

sentindo, espera-se que mesmo os alvos agrícolas que apresentam similaridade espectral em suas respostas nas imagens, (colo solo exposto e áreas urbanas), podam ser particularizados ao incorporar atributos temporais como critério de decisão para distinção. Tendo em vista as premissas acima indicadas, os objetivos gerais desta pesquisa foram:

- a) Caracterizar o uso e cobertura da terra na região centro-leste do Estado de São Paulo através de séries temporais de imagens orbitais de média resolução espacial, feitas a partir dos sensores OLI e MSI;
- b) Utilizar os algoritmos de classificação de imagens do sistema de geoprocessamento em nuvem GEE para classificar os alvos terrestres presentes nas respectivas séries temporais, tendo como resultados mapas mensais de uso e cobertura da terra;
- c) Explorar as etapas descritas nos procedimentos metodológicos como recurso didático de apoio a rotinas de geoprocessamento.

Os objetivos específicos desta pesquisa foram:

- a) Utilizar métodos de classificação pixel a pixel e orientado a objeto, a partir da arquitetura do tipo árvore de decisão como abordagem para combinação de dados de sensoriamento remoto e padrões temporais de variação espectral;
- b) Avaliar o desempenho dos classificadores com base nos resultados dos testes de validação do processo de classificação das imagens de sensoriamento remoto.

3. REVISÃO BIBLIOGRÁFICA

Partindo do objetivo principal desta pesquisa de caracterizar o uso e cobertura da terra a partir de técnicas de sensoriamento e geoprocessamento aplicados à análise geográfica, até os objetivos específicos de avaliação dos métodos de mapeamento, utiliza-se uma série de métodos provenientes do conhecimento acumulado ao longo do desenvolvimento do Sensoriamento Remoto e do Geoprocessamento como áreas do conhecimento que fornecem suporte para o desenvolvimento de várias ciências, dentre elas a Geografia.

Ao longo de seu desenvolvimento como ciência, temos que o tema central da geografia é o entendimento de uma determinada porção do espaço em um intervalo de tempo onde ocorrem as interações entre os fenômenos ambientais, representados pelos geossistemas ou sistemas ambientais; e sociais, representado pela reprodução das relações humanas no que se refere aos aspectos socioeconômicos e culturais (ROSS, 2019, p. 16). Essa interação espaço-temporal dos fenômenos sociais e ambientais, nos dias atuais, é moldada pela componente da informação, que surge como uma categoria capaz de produzir efeitos sobre o contexto espaço-temporal ao qual as sociedades estão sujeitas. A natureza do conceito de informação como componente da produção espaço-temporal diz respeito ao conhecimento (e também propriedade do conhecimento) de toda sorte de fatos, eventos, acontecimentos, em razão dos quais as dinâmicas espaço-temporais podem ser modificadas no que diz respeito ao seu contexto socioambiental. A título de exemplo, temos que as informações sobre as reservas de ouro e prata nas Américas, exploradas durante os séculos XV e XVI exerceram uma grande influência sobre as esferas social, econômica e ambiental sobre o plano espaço-temporal da época. A dinâmica deste contexto social, econômico e ambiental e seus desdobramentos no tempo e no espaço, eram em grande parte influenciados pela fluidez e velocidade com que a informação era transmitida. Este padrão permanece nos dias atuais e possui um peso muito mais relevante.

Nos dias atuais, considera-se que o avanço tecnológico das redes de transmissão, armazenamento de modelagem de dados, a informação é gerada, transmitida e assimilada quase que de maneira instantânea, fazendo com que as dimensões espaciais e temporais adquiram grande fluidez e lancem novos desafios para o entendimento da construção do espaço (SANTOS. 2013, p. 29). Tendo em vista o avanço da tecnologia da informação e a forma como essas tecnologias

locacionais influenciam na construção do espaço geográfico, Longley *et al.* (2013, p. 18) situam a ciência da informação geográfica como um conceito chave para o entendimento das dinâmicas espaço-temporais influenciadas pela fluidez e volume de informações geradas diariamente.

Neste contexto, de acordo com Longley *et al.* (2013, p. 15), a ciência da informação geográfica, fornece as ferramentas para o entendimento da dinâmica espaço temporal moldada pelo contexto da hiper conectividade e transmissão de dados quase que instantaneamente. Desta forma, a ciência da informação geográfica aplicada ao monitoramento das atividades de uso e cobertura da terra, possui capacidade de proporcionar economia de recursos e sustentabilidade.

Os produtos de sensoriamento remoto, através de suas séries temporais de imagens multiespectrais, carregam consigo valiosas informações sobre a dinâmica de uso e cobertura da terra. Aliado a técnicas computacionais que permitem o processamento de grandes quantidades de dados espaciais, é possível a obtenção de uma visão sinóptica do contexto espaço-temporal de qualquer ponto da superfície terrestre onde haja o desenvolvimento de qualquer atividade de caráter humano que, em um contexto mais amplo, terá desdobramentos sociais, econômicos e ambientais sobre o espaço. Neste sentido, as técnicas de mapeamento de uso e cobertura da terra contribuem para o entendimento de parte da dinâmica de interação das esferas social, ambiental e econômica. Uma vez que o conhecer a localização precisa das culturas agrícolas podem fornecer informações de caráter estratégico para segurança alimentar, previsão de safras, otimização da alocação de insumos, podendo colaborar para o entendimento da organização do espaço no meio rural.

Deste modo, os mapas e produtos cartográficos podem apresentar-se como uma ferramenta de síntese, que retrata o uso e cobertura da terra ao longo do tempo num determinado espaço, representando graficamente padrões de uso e cobertura da terra e as mudanças socioambientais decorrentes de cada padrão. Em se tratando do mapeamento das áreas agrícolas, fundamental para o entendimento da dinâmica espacial rural, o desenvolvimento de ferramentas automáticas de mapeamento, baseadas em técnicas de geoprocessamento e sensoriamento remoto, pode conduzir a uma eficaz gestão do espaço agrícola, devido acurácia e precisão geográfica. Neste aspecto, Wang *et al.* (2019, p. 303) relatam que várias agências governamentais e grupos de pesquisa de universidades, vêm empreendendo esforços no sentido de elaborar mapeamentos precisos das diversas culturas agrícolas cultivadas sobre a superfície terrestre. Estes produtos cartográficos, gerados a partir do mapeamento espaço temporal das culturas agrícolas, são importantes para tratar de assuntos relevantes e de interesse de vários atores sociais que se interessam por questões

relacionadas com segurança alimentar através da previsão de safras, com o monitoramento agrícola, no que diz respeito à gestão da lavoura e no aspecto de como as mudanças climáticas impactam a agricultura, o manejo de recursos hídricos, modelagem de uso da terra, e a modelagem de sistemas ambientais.

3.1 Uso e cobertura da terra e mudanças ambientais

Em se tratando de estudos relacionados com o uso e cobertura da terra, torna-se conveniente uma entre os conceitos “uso da terra” e “cobertura da terra”. Conforme Meyer e Turner (1996, p. 237), o termo cobertura da terra possui relação com as propriedades naturais do planeta, situadas no campo dos processos biológicos, químicos e físicos que promovem ao funcionamento dos ecossistemas. Essas são áreas ocupadas por água, neve, rochas e florestas naturais. Quando tratamos do termo “uso da terra”, adicionamos a componente da ação humana sobre este sistema, uma vez que o “uso” pressupõe que o ser humano se utiliza da apropriação de um recurso natural para um determinado fim. Neste sentido, a partir de determinados usos da terra, pode-se obter uma noção sobre o grau de alteração de determinado ecossistema.

Ao longo de sua história e evolução, a humanidade desenvolveu métodos de organização e cooperação social que lhe garantiram a sobrevivência e prosperidade sobre o planeta Terra. Estas formas de se organizar socialmente são um dos principais fatores condicionantes do desenvolvimento cultural e tecnológico da humanidade. Esta capacidade de se organizar e colaborar socialmente se torna ainda mais evidente quando observadas sobre o aspecto das relações entre o homem e a natureza, uma vez que é proveniente desta relação todos os subsídios necessários para manutenção da vida humana, seja ela considerada sobre aspectos naturais-biológicos, ou segundo os aspectos construídos socialmente, inerentes às características culturais dos grupos humanos.

Em se tratando dos processos naturais necessários para manutenção da vida na Terra, têm-se os ciclos biogeoquímicos que são responsáveis pela ciclagem e renovação dos principais elementos dos sistemas Terra, garantindo o equilíbrio dos ecossistemas. Como exemplo, temos os ciclos do CO₂, N, P e K; e no mesmo contexto, o ciclo das rochas que se situa na base dos processos de formação de minerais de aproveitamento econômico e na formação do solo; o ciclo da água, fundamental para manutenção dos ecossistemas terrestres. Quando nos referimos à manutenção dos padrões socialmente construídos, remete-se à ideia do modelo de exploração e transformação

dos recursos naturais, convertendo-os em energia e bens de consumo, fato este no cerne de toda uma cadeia que envolve economia e padrões de consumo e, por conseguinte, diversos desdobramentos nos contextos políticos, históricos e culturais em uma sociedade.

A relação entre o homem e a natureza constitui a base dos modelos socioeconômicos em um amplo contexto global que é pautado na exploração de tais recursos para atender as demandas alimentares, energéticas e de consumo das sociedades. Este contexto socioambiental vem demonstrando sinais de capacidade de alterar o funcionamento natural dos geossistemas em seus fluxos de matéria e energia colocando em risco a resiliência dos sistemas terrestres. Este quadro tem fomentando o debate no eixo das mudanças ambientais, dentre essas o aquecimento global, elevação do nível dos oceanos, secas e perda do solo devido a processos erosivos (ZALASIEWICZ *et al.* 2017, p. 197). A exploração dos recursos naturais como solo, água, minerais, entre outros recursos de aproveitamento econômico e energético, exercem influência sobre a forma como as sociedades ocupam a superfície terrestre e a agricultura possui um papel relevante no contexto do uso e cobertura da superfície terrestre, uma vez que a atividade agrícola se estabelece na base do fornecimento de fibras, proteínas, grãos entre outros produtos que garantem segurança alimentar e fornecimento de matérias primas.

O uso do espaço pela atividade agrícola é de grande interesse da geografia como demonstram os trabalhos de Caldarelli e Gilio (2018) que estudaram os efeitos da expansão da agroindústria da cana-de-açúcar e os seus efeitos sobre o uso da terra no Estado de São Paulo no período entre os anos de 2000 e 2015; Tramberand *et al.* (2019), propuseram procedimento metodológico que permitiu correlacionar o uso da terra pela agricultura e perspectivas de consumo em escala global, servindo como base para o planejamento de ações pertinentes a segurança alimentar, estoque e preços de commodities agrícolas; Adami *et al.* (2012), através de séries temporais de imagens de sensoriamento remoto analisaram mudanças nos padrões de uso da terra devido à expansão da cana de açúcar em todo território brasileiro, permitindo correlações entre a área plantada, produtividade e lucro gerado; Lathuillière *et al.* (2017), analisaram os impactos causados pela expansão da cultura de soja na região sul do bioma amazônico, fato que está no centro dos debates sobre o papel do bioma amazônico na regulação do clima em escala global; e, Silva Junior *et al.* (2018), utilizaram técnicas avançadas de geoprocessamento e sensores hiperespectrais não imageadores para fazer distinção entre quatro variedades de soja cultivadas no Mato Grosso do Sul, permitindo fazer estimativas sobre a adaptabilidade de cada espécie de soja a

condições inerentes ao ambiente. As evidências apresentadas nos trabalhos conduzem a reflexões sobre o uso da terra e os impactos sobre os geossistemas.

De acordo com Ellis *et al.* (2017, p. 192), as atividades humanas vêm alterando o planeta a partir do Holoceno onde, nos últimos dez mil anos, observam-se evidências de extinções em massa, mudanças globais na distribuição de elementos da fauna e da flora, aceleração das taxas erosivas e liberação de gases do efeito estufa, decorrentes da queima de combustíveis fósseis, da retirada da cobertura vegetal, e através da produção de materiais como cerâmica e concreto, quando após seu descarte se tornam poluentes e alteram o ambiente. No entanto, os efeitos de atividades das primeiras civilizações se davam somente em escalas locais, de forma que o sistema Terra não era afetado em escala global. Este cenário começa a se alterar na medida em que o conhecimento humano e as ciências avançavam, permitindo assim a criação de tecnologias e técnicas que, em seus devidos contextos históricos, pavimentaram o caminho do desenvolvimento das sociedades humanas (SANTOS, 2013, p. 57). Este contexto gerou o atual quadro de mudanças ambientais, objeto de discussão em vários segmentos governamentais e mundiais dentre eles o IPCC, RIO +20, entre outros.

A este respeito, Zalasiewicz *et al.* (2017, p.198) observam que a partir da segunda metade do século XX, as atividades humanas deflagraram processos de alterações no meio ambiente em uma magnitude capaz de alterar a paisagem terrestre e os ciclos biogeoquímicos em nível global a uma taxa jamais registrada na escala de tempo geológico. Nesse sentido, a capacidade humana de alterar o meio ambiente vem sustentando debates acadêmicos sobre a proposição de uma nova unidade na tabela cronoestratigráfica denominada Antropoceno, que corresponde a um período de rápidas mudanças na geologia e nos ecossistemas em escala global, decorrentes de diversas formas de ação humana.

Evidências das alterações ambientais observadas nos sistemas terrestres são descritas por Waters *et al.* (2016, p. 139), que elencam uma vasta gama de estudos que sustentam que as ações e atividades humanas possuem a capacidade de alterar os geossistemas. Dentre essas evidências, os autores destacam a existência dos depósitos antropogênicos, decorrentes da disseminação do uso e acúmulo de materiais utilizados em grande escala pela construção civil e diversos segmentos da indústria, constando como principais materiais o alumínio, concreto e plástico.

As alterações observadas nos ecossistemas estão relacionadas com uma complexa cadeia de fatores e agentes socioambientais, dentre eles o uso e a cobertura da terra, ou seja, é resultado

da finalidade pela qual o território é utilizado e ocupado pelas sociedades. Essas formas de cobertura da terra envolvem diversos fins como instalação de infra estruturas urbanas, áreas de cultivo agrícola, silvicultura, pastagens, mineração, infra estrutura industrial, reservatórios de usinas hidrelétricas, dentre outras formas de uso de grandes porções da superfície terrestre. Waters *et al.* (2016, p. 140), relatam sobre a existência de depósitos antropogênicos contendo novos minerais e tipos de rochas, resultante da intensificação do uso de materiais como alumínio, concretos e plásticos, cujo acúmulo em aterros sanitários ou áreas sem controle, caracterizam a existência e evolução de tecnofósseis. Dentre as alterações ambientais decorrentes do uso da terra, Zalaciewicz *et al.* (2014, p. 48) evidenciam o aumento de fluxos de sedimentos denominados de origem antropogênica, que são decorrentes da intensificação das taxas erosivas causadas principalmente pela instalação de infraestrutura urbana e atividades agropecuárias. Também, são observados por meio de várias pesquisas, alterações nos ciclos de nitrogênio, fósforo e potássio em decorrência das atividades de caráter agropastoril, bem como alterações no ciclo de carbono em função da poluição atmosférica (STEFFEN *et al.*, 2007 e 2015; CANFEILD *et al.*, 2010; CARPENTER e BENNETT, 2011). Zalaciewicz *et al.* (2015, p. 198) relatam a o aumento de radionuclídeos e metais pesados na atmosfera como consequência de testes de detonação de armas nucleares, ocorridos entre os anos de 1950 e 1970 e da queima de combustíveis fósseis; Geherel *et al.* (2013, p. 219) e Kemp *et al.* (2015, p. 225) relatam alterações do nível dos mares em decorrência do derretimento do gelo polar, bem como o aumento das temperaturas médias globais. Tais eventos vêm alterando os balanços de energia do sistema Terra, alterando as dimensões espaciais e temporais dos eventos geológicos a uma taxa diferente daquela observada em épocas anteriores ao Holoceno (WATERS *et al.* 2016, p. 135).

Considerando o contexto das mudanças ambientais desencadeadas pela ação antrópica, podemos afirmar que o uso e cobertura da terra é uma categoria de fundamental importância para o entendimento do quadro das mudanças ambientais em escala global sugerido pela proposição do termo Antropoceno como uma nova época na escala cronoestratigráfica (ZALASIEWICZ *et al.* 2015, p. 197). Neste sentido, a forma com a qual as sociedades se apropriam e utilizam a faixa emergida e habitável da Terra consiste em um dos principais temas a serem discutidos no contexto das mudanças ambientais que sustentam indícios sobre a capacidade das ações humanas alterarem os ecossistemas terrestres. Hooke *et al.* (2012, p. 5), através de uma revisão bibliográfica e estatística de dados relacionados à cobertura da terra, estimam que mais de 50% da superfície

terrestre já sofreu algum tipo de modificação em função da crescente demanda por recursos naturais e pressões demográficas. Em termos de área, a porção da superfície terrestre ocupada por áreas de pastagem, cultivo agrícola e silvicultura corresponde a 60,6 milhões de Km², o que corresponde a 46,6% da superfície terrestre, enquanto as áreas ocupadas por todos os tipos de infraestruturas urbanas recobrem uma área de 9 milhões de Km², que corresponde a 6,9% da superfície terrestre (Hooke *et al.* 2012, p. 8). Desta forma, verifica-se que as únicas áreas que não sofreram algum tipo de impacto direto, são aquelas consideradas inóspitas, como cinturões orogênicos, os desertos e as regiões polares.

De acordo Giri (2012, p. 71), a compreensão das dinâmicas de uso e cobertura da terra é crucial para o entendimento dos sistemas terrestres, no que diz respeito às suas dinâmicas e características, dentre elas a produtividade da terra, diversidades paisagísticas, fauna, flora, e os ciclos hidrológicos e biogeoquímicos. Segundo a autora, os usos e coberturas da terra também desempenham um papel crucial na regulação da temperatura do planeta, uma vez que nos últimos 150 anos, foram responsáveis pela liberação de grandes quantidades de carbono para atmosfera, correspondendo a cerca de 20% do total de emissões de gases do efeito estufa que tem como origem as atividades antrópicas. Embora o uso e cobertura da terra tenham um peso relevante no contexto da liberação de gases do efeito estufa, a principal fonte de emissão continua sendo àquela proveniente da queima de combustíveis fósseis.

3.2 Uso e cobertura da terra e sua relação com as atividades agrícolas

Em se tratando do uso da terra, as culturas agrícolas ocupam uma parcela significativa da superfície terrestre e tem ganhado atenção especial dos trabalhos de monitoramento dessa atividade econômica. As escalas de mapeamento de culturas agrícolas variam desde a escala global, até os níveis regionais e locais de mapeamentos, uma vez que a evolução dos sistemas de sensoriamento remoto refletiu na produção de imagens com melhor resolução espacial, e espectral, permitindo discriminar e mapear, em escala de detalhes, as culturas agrícolas. Soma-se a este fato o aumento da resolução temporal através da operação de constelações de satélites como o sistema SENTINEL-2 da Agência Espacial Europeia (ESA). O refinamento da resolução temporal, juntamente com avanços nos sistemas de classificação de uso da terra, tem gerado bons resultados nos trabalhos de mapeamento de culturas agrícolas em escalas global, regional e local.

Mapeamentos de áreas agrícolas em escala global compreendem produtos cartográficos

gerados em pequena escala, que abrangem amplas faixas da superfície terrestre e são produzidos a partir de dados de sensores com resolução espacial entre 250 e 1000 metros. O sensor MODIS (Moderate Resolution Imaging Spectroradiometer), operado a partir dos satélites TERRA e AQUA, é um exemplo de sistema sensor de baixa resolução espacial, cujo as aplicações são utilizadas para mapear amplas faixas da superfície terrestre. Apesar da baixa resolução espacial, que limita a capacidade do sistema sensor em registrar formas e geometrias de objetos e fenômenos, o sensor MODIS possui uma grande resolução espectral, que fornece uma grande variedade de dados dispostos em 36 bandas espectrais, permitindo obter significativas informações sobre a dinâmica de funcionamento dos sistemas terrestres. Em se tratando do monitoramento de culturas agrícolas, Chen *et al.* (2018) utilizaram dados das bandas espectrais do sensor MODIS para elaborar séries históricas de índices de vegetação NDVI (Normalized Difference Vegetation Index), que permitiram a identificação dos padrões fenológicos das culturas de soja, algodão e milho cultivados no Estado do Mato Grosso, na região Centro Oeste do Brasil, de forma que o método foi eficaz na identificação das respectivas culturas, bem como na projeção de estimativas sobre a área cultivada e a produtividade local.

Além de dados diretos produzidos a partir dos sensores orbitais, dados de censos e estatísticas oficiais de Instituições governamentais contribuem para o refinamento das técnicas de mapeamento de culturas agrícolas. Monfreda *et al.* (2008) utilizaram técnicas de sensoriamento remoto, geoprocessamento e estatísticas oficiais de agências governamentais para produzir dados cartográficos de escala global, onde foi modelada a distribuição espacial de 175 culturas agrícolas em 206 países. Os dados mostram a predominância das culturas milho, arroz, trigo e soja distribuídos ao longo das latitudes intertropicais. Wu *et al.* (2015) aplicaram abordagem de análise de dados a partir de múltiplos sensores para realização de mapeamento de cultivos agrícolas em quatro níveis hierárquicos: global, regional, nacional. Os resultados incluíram trinta e um países que juntos correspondem por 80% da produção e exportação de milho, arroz, soja e trigo, servindo de suporte para o planejamento das atividades de produção, comércio e consumo das culturas agrícolas mapeadas.

Além de buscar distinguir entre os tipos de culturas cultivadas no espaço agrícola, a abordagem de Xiong *et al.* (2017), contribuiu para o entendimento da distribuição das culturas agrícolas em meio a heterogeneidade paisagística do continente africano. Através de ferramentas de automação processadas no Google Earth Engine, os autores utilizaram dados do sensor MODIS,

amostras de treinamento de alta resolução espacial, estatísticas oficiais e dados de campo e séries temporais do Índice de Vegetação por Diferença Normalizada (NDVI) com resolução espacial de 250 metros. A partir desses dados, foram produzidos mapas de extensão das terras cultivadas, áreas irrigadas e de sequeiro, dominância de culturas entre outros atributos que contribuíram para a construção de entendimento das dinâmicas agrícolas no território africano, tarefa essa que persiste até os dias atuais e vem se tornando cada vez mais precisa em função dos resultados de pesquisas que lançam mão de novas tecnologias e abordagens metodológicas que geram produtos com elevada precisão e qualidade.

De acordo com Wu *et al.* (2019), mapeamentos de culturas agrícolas em média escala são aqueles que tomam por base imagens dos sistemas orbitais MODIS, LANDSAT e SENTINEL-2, podendo ser incluído neste grupo os sistemas CBERS (Satélite Cino Brasileiro de Recursos Terrestres) e HysIS (Indian Hyperspectral Imaging Satellite). Em áreas onde predominam grandes campos de cultivo com culturas individuais, como a cana-de-açúcar no Estado de São Paulo e a soja nos Estados do Mato Grosso e Mato Grosso do Sul, os produtos cartográficos de média resolução permitem o estudo e categorização das culturas agrícolas. Exemplos de mapas de culturas agrícolas gerados a partir de sistemas de média resolução espacial são apresentados na pesquisa de Cai *et al.* (2018) que elaboraram um sistema de classificação para as culturas de milho e soja na região do *Corn Belt* norte americano a partir de séries temporais de dados do sensor OLI. Os autores concluíram que os melhores dados para classificar milho e soja são aqueles obtidos a partir das bandas do infravermelho de ondas curtas (SWIR), de forma que a metodologia utilizada obteve uma acurácia de 95% quando comparada com dados oficiais do Departamento de Agricultura dos Estados Unidos (USDA). No Brasil, Silva Júnior *et al.*, (2014) utilizaram dados do sensor MODIS para elaborar o índice de vegetação realçado (EVI) a partir de doze cenas compreendendo a safra e a entressafra na região sul do Estado do Maranhão, os autores utilizaram o método de classificação orientada a objeto através dos algoritmos “classification” e “merge region”. Os resultados obtidos indicam que a metodologia proposta se mostrou eficiente para mapeamento da soja, com índice Kappa de 0,89.

Mapeamentos de culturas agrícolas realizados a partir de imagens com alta resolução espacial menor que dois metros são escassos na literatura, devido ao alto custo de aquisição dessas séries temporais e da alta capacidade computacional necessária para processar esses dados. Como exemplos de mapeamentos que utilizam séries temporais de alta resolução espacial, temos a

pesquisa de McCarty *et al.* (2017), que utilizaram a plataforma de processamento de dados “Advanced Data Analytics Platform” da NASA (National Aeronautics and Space Administration) para mapear pequenas propriedades agrícolas na região de Tigray na Etiópia. Os dados resultantes do processo de segmentação das imagens WorldView-1 e WorldView-2, com 1,84 metros de resolução espacial, foram combinadas com dados do LANDSAT 8 para obtenção de dados dos estágios fenológicos da vegetação registrada no interior das pequenas propriedades agrícola. Através dos mapas gerados, foi possível estimar que 46% da região de Tigray é ocupada por cultivos agrícolas. Yang *et al.*, (2007) utilizaram dados de 2,8 metros de resolução espacial, coletados pelo sistema QuickBird, para identificação de culturas e estimativas de áreas de cultivo no sul do Estado do Texas nos Estados Unidos da América. A metodologia utilizada pelos autores foi eficaz para identificar as culturas de sorgo, algodão, citrus e cana-de-açúcar. Os autores ainda identificaram cinco classes de uso e cobertura da terra na área de estudo: corpos d’água, áreas úmidas, espécies herbáceas mistas, arbustos mistos e solo exposto.

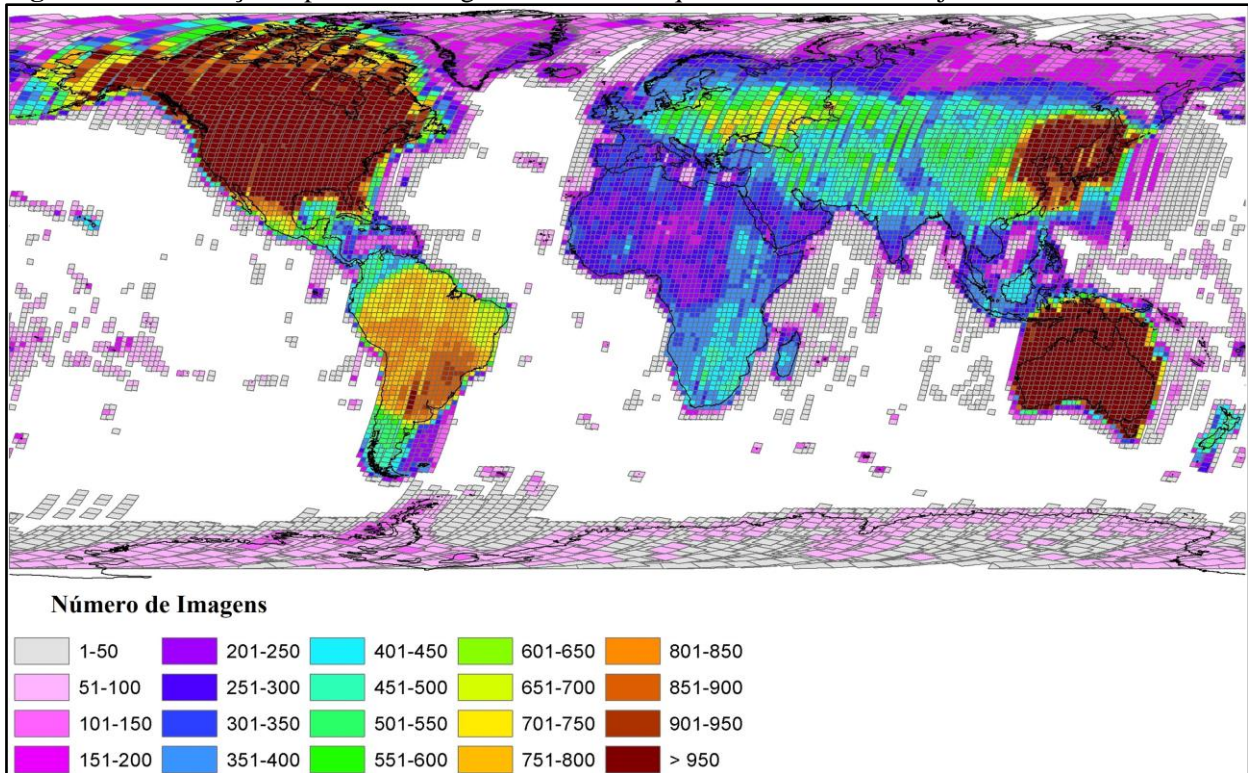
No Brasil, a maioria das formas de monitoramento de culturas agrícolas são realizadas através de questionários e trabalhos de campo feito pelas Secretarias de Agricultura e Abastecimento dos municípios e pelo Censo Agrícola do IBGE (Instituto Brasileiro de Geografia e Estatística), publicados em períodos de tempo diversos, fato que gera um grande lapso de tempo entre a data da coleta da informação e sua respectiva publicação. Neste sentido, considerando a importância da atividade agrícola no âmbito do desenvolvimento sócio ambiental, de forma a conciliar desenvolvimento econômico, produtividade e sustentabilidade ambiental, esta pesquisa teve como o objetivo a proposição de proposta metodológica a partir da classificação supervisionada dos produtos de reflectância de superfície dos sistemas LANDSAT 8 e SENTINEL-2, aliadas com sistemas de árvores de decisão e aprendizado de máquina, para obter mapeamentos automáticos em nível de semi-detalle (1:50000) das culturas agrícolas cultivadas na região centro leste do Estado de São Paulo. As séries temporais foram processadas através do sistema de computação na nuvem de alto desempenho, disponibilizado através da plataforma Google Earth Engine.

A utilização de imagens de sensores de média resolução espacial foi popularizada pelas plataformas abertas de dados espaciais, dentre elas o portal “Earth Explorer” de responsabilidade do USGS (United States Geological Survey – Serviço Geológico dos Estados Unidos da América), que disponibiliza, quase que em tempo real, todas as imagens coletadas pela série de satélites das

missões LANDSAT, entre outros dados espaciais que recobrem principalmente o território dos EUA. O portal “Schi-Hub”, de responsabilidade da ESA (European Space Agency – Agência Espacial Europeia), distribui dados coletados pelas missões SENTINEL. No Brasil, o INPE (Instituto Nacional de Pesquisas Espaciais) disponibiliza o Catálogo de Imagens do portal DGI-INPE (Divisão de Geração de Imagens – Instituto Nacional de Pesquisas Espaciais), que fornece os produtos das missões CBERS, bem como produtos do sensor MODIS dos satélites AQUA e TERRA, operados pela agência NOAA (National Oceanic and Atmospheric Administration); o sistema S-NPP (Suomi National Polar-orbiting Partnership); produtos de todas os satélites da série LANDSAT; e dados dos satélites RESOURCESAT-1 e 2, pertencentes ao Programa Indiano de Observação da Terra IRS (Indian Remote Sensing Satellite).

Dentre todos os programas das agências espaciais voltados para a pesquisa dos recursos terrestres, o de maior tempo de operação e que apresenta as séries temporais mais longas, são os produtos das missões LANDSAT. De acordo com Woulber et al. (2016, p.218), através do programa “LANDSAT Global Archive Consolidation” de iniciativa do USGS, todas as cenas das missões LANDSAT foram reunidos em uma plataforma universalmente acessível que é constituída pelo sistema EROS (Earth Resources Observation and Science). Segundo o autor até o dia 1 de janeiro de 2015, existiam 5.323.454 cenas das missões LANDSAT armazenados nos servidores do USGS. Hoje estima-se que este número tenha duplicado dada a capacidade de processamento e armazenamento de dados do USGS. As séries temporais de imagens das missões LANDSAT abrangem toda superfície terrestre de forma que o maior número de cenas disponíveis é da América do Norte, conforme demonstrado na figura 2.

Figura 2: Distribuição espacial de imagens LANSAT arquivadas no USGS até jan/2015



FONTE: Adaptado de Woulber *et al.*, (2016).

Tais iniciativas têm promovido a universalização do uso de dados espaciais e, conseqüentemente, no aumento das pesquisas que utilizam dados de sensoriamento remoto, conforme demonstrado nas pesquisas citadas anteriormente.

3.3 Geotecnologias aplicadas ao ensino e análise geográfica

O Sensoriamento Remoto e o Geoprocessamento aplicados ao ensino e a análise geográfica, fazem parte de um conjunto de disciplinas que, de acordo com Fitz (2005, p. 36) situam-se no campo das geotecnologias ligadas às geociências e, devido ao avanço das tecnológicas de pesquisa, passam por constantes quebras de paradigmas e impulsionam a evolução de uma ciência, conforme descrito Khun (1997, p. 94). Fitz (2005, p. 37) descreve uma linha do tempo destacando a evolução e inserção das ferramentas de análise espacial à disposição o ensino, conforma a tabela a seguir:

Tabela 1 - Evolução das ferramentas de análise espacial.

Época	Avanço tecnológico
3.800 a. C,	Utilização de Coordenadas Esféricas
Séc. III a. C.	Representação Plana
Séc. II	Uso de Projeções cartográficas
Séc. XVII	Noção de Geóide
Séc. XVIII	Utilização de Isolinhas
1920	Surgimento da aerofotogrametria
1960	Surgimento da cartografia digital e dos SIGs
1963	1º SIG - Canadian Geographic Informations System (CGIS)
1969	Fundação da ESRI – Environmental Systems Research Institute
1972	Missão LANDSAT
1979	Sistemas GNSS (Global Navegation Satellite System)
1981	Surgimento da Internet
1997	Sensor Thematic Mapper – LANDSAT 7
1999	1º Sistemas com 1 metro de resolução espacial: IKONOS
2001	Google Earth
2005	Google Maps
2007	Google Street View
2015	Sensor WorldView-3 (30 com resolução espacial)

FONTE: FITZ, 2005.

Neste contexto, partir dos anos 2000 houve uma popularização do uso de SIG's com a inserção SIG's (Sistemas de Informação Geográfica) de uso aberto, dentre eles o SPRING, disponibilizado pelo Departamento de Processamento de Imagens (DGI/INPE), e os SIGs de uso comercial, dentre eles o ArcGis, fornecido pela ESRI (Environmental Systems Research Institute).

A partir dos anos 2010 observamos o fortalecimento das comunidades de usuários e desenvolvedores de plataformas abertas para o processamento de dados geoespaciais, onde se destaca o SIG QGIS. A partir de 2017 ocorre a expansão das capacidades de processamento de dados aliada com a universalização do acesso a dados geoespaciais, fornecidos pela plataforma Google Earth Engine. Dadas às capacidades de análise fornecida pela ferramenta, concordamos com Golerick *et al.* (2017, p. 17) quando destaca que a inclusão do Google Earth Engine representa uma grande evolução no acesso e processamento de dados espaciais pois é uma plataforma capaz de atender não somente o público especializado das geociências, mas também o público não especializado nas aplicações científicas.

Além das contribuições recentes do GEE, o campo do conhecimento que mais contribuiu para o fortalecimento das geotecnologias foi o Sensoriamento Remoto, através das missões de observação da Terra. De acordo com Fussel *et al.* (1986, p. 1507), o termo “Sensoriamento Remoto” está relacionado com a aquisição de informações de um determinado alvo de maneira indireta, sem que ocorra contato físico com o mesmo, de forma que a obtenção das informações se dá através da quantificação dos fluxos da radiação eletromagnética refletida ou emitida pelos alvos. Neste sentido, Fussel *et al.* (1986, p. 1508) consideram que o termo Sensoriamento Remoto transita entre três campos de agrupamento que se sobrepõem: como uma ciência ou arte, uma ferramenta ou técnica, uma atividade ou função. Considerando seu aspecto científico, o Sensoriamento Remoto usa sensores para medir e registrar à distância a radiação eletromagnética refletida ou emitida pelos alvos na natureza. Posteriormente, implementa-se o uso de algoritmos computacionais baseados em matemática e estatística para manipular e extrair informação útil para algum fim. Visto pelo ângulo da arte, de acordo com Jessen (2012, p. 274), o termo Sensoriamento Remoto, se refere à experiência que intérprete adquire ao longo de sua experiência de vida, fato que lhe fornece elementos que sustentam a aplicação do seu conhecimento à interpretação dos elementos paisagísticos registrados em uma fotografia aérea ou em uma imagem digital.

O segundo agrupamento discute a consolidação do campo do Sensoriamento Remoto como uma ferramenta ou técnica. Sua utilização está voltada para a solução de problemas ou para o estudo de um fenômeno natural ou humano. Citam-se como exemplos as aplicações dos sistemas AQUA e TERRA operados pela NASA, e o sistema geoestacionário GOES (Geoestacionary Operational Environmental Satellite), operado pela NOAA (National Oceanic and Atmospheric Administration). Estes sistemas são aplicados ao monitoramento das condições atmosféricas,

oceânicas e terrestres, de forma que seus dados são aplicados na previsão do tempo, modelagem de mudanças climáticas e no monitoramento de desastres naturais.

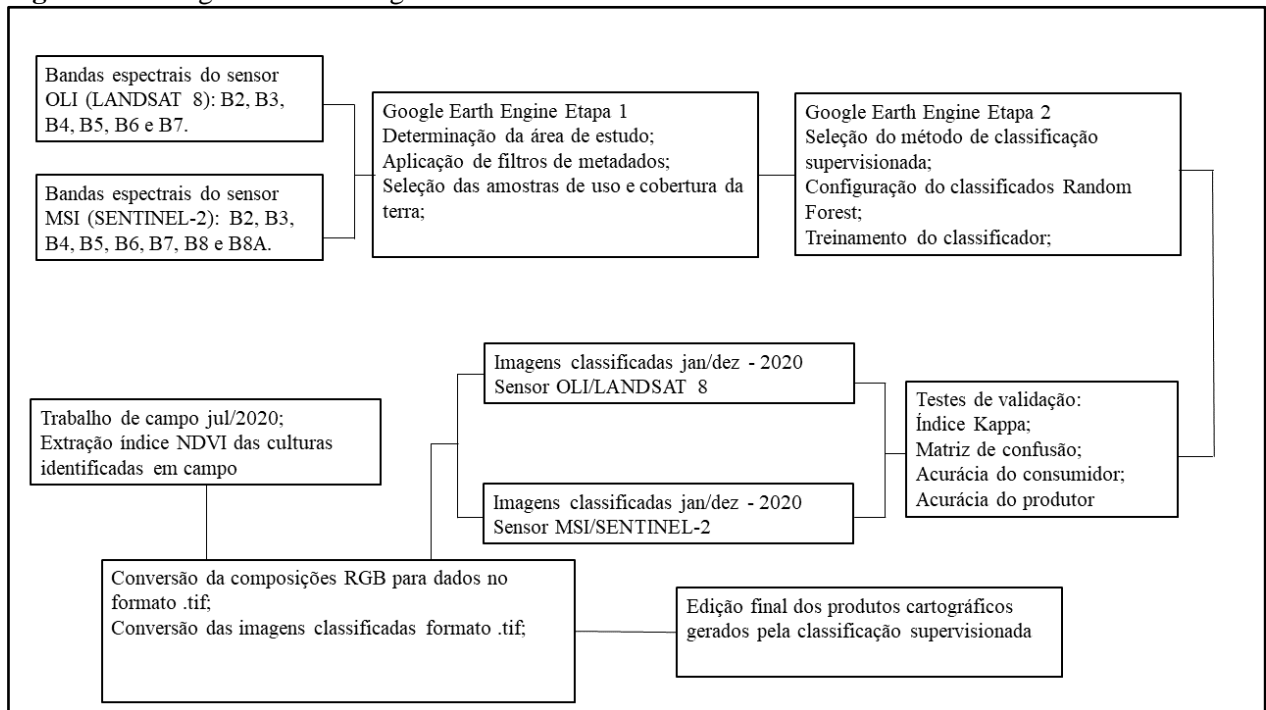
O terceiro agrupamento o tem em vista como atividade ou função no âmbito da prática por profissionais e pesquisadores da área. De acordo com este espectro de análise, o Sensoriamento Remoto e os Sistemas de Informação Geográfica se apresentam como principal instrumental metodológico, bem como ferramenta de síntese para compreensão das múltiplas configurações da superfície terrestre que são influenciadas pela ação humana.

O desenvolvimento de uma área do conhecimento surge a partir da necessidade de se encontrar uma solução para algo, a resposta para determinada questão filosófica, ou ainda em função do desenvolvimento de técnicas que promovam o desenvolvimento humano. Em se tratando da estrutura da evolução das áreas do conhecimento, Kuhn (1997 p. 105), estabelece que esta evolução é caracterizada por marcos conceituais que promovem o avanço tecnológico e conceitual de uma área do conhecimento, caracterizando as mudanças de paradigmas que promovem o avanço da ciência. Em se tratando do Sensoriamento Remoto, área do conhecimento extremamente nova, e contextualizando-a com os marcos conceituais estabelecidos pelos estudos de Kuhn (1997), Jessen (2011, p. 84) estabelece três momentos cruciais para o desenvolvimento do Sensoriamento Remoto. O primeiro é entre 1860 e 1960 e está embasado em técnicas de fotografias a partir de plataformas aéreas como balões e aeronaves. O segundo momento vai de 1960 até 1970, com introdução de múltiplos sensores, radares, espectro radiômetros transportados a partir de aeronaves. A partir de 1970 a corrida espacial amplia as possibilidades do sensoriamento remoto a partir do desenvolvimento de veículos lançadores de satélites (VLS) e motores propulsores capazes de colocar grandes volumes de carga na órbita da Terra. Nos dias atuais, a fronteira do sensoriamento remoto orbital é explorada pelas grandes empresas privadas de tecnologia, dentre elas a SpaceX e a Virgin Galactic.

4. MATERIAIS E MÉTODOS.

Os procedimentos metodológicos desta pesquisa se baseiam na programação da plataforma GEE através da linguagem de programação JavaScript, que permite inserir as informações e executar comandos de tarefas, preferencialmente através do navegador de internet Google Chrome. Através da interface do navegador, as instruções para a execução das rotinas de geoprocessamento são transferidas para os servidores do GEE. Os principais materiais desta pesquisa são dados extraídos de imagens óticas dos sensores OLI, a bordo do satélite LANDSAT 8; e MSI, a bordo do satélite SENTINEL-2. As séries históricas dos respectivos sensores abrangem o período de janeiro a dezembro de 2020, de forma que os dados foram processados no Google Earth Engine através do algoritmo de classificação “Random Forest”, conforme síntese metodológica representada no fluxograma de trabalho na figura 3.

Figura 3: Fluxograma metodológico.



Fonte: Elaborado pelo Autor.

Todos os procedimentos metodológicos descritos a seguir foram feitos a partir de do scripts inseridos através do API do GEE. Neste sentido, o processo de mapeamento do uso e cobertura da terra inicia-se com a delimitação da área de estudo no GEE. Este processo é feito através da inserção de dados vetoriais externos, ou através das próprias ferramentas de interface do GEE, que

permitem selecionar a área de estudo sobre os planos de informação de base da ferramenta. Para execução deste pesquisa, a área útil classificada compreende um perímetro de 400 quilômetros em uma quadrícula de 110 x 110 km sobreposta às cenas das órbitas 220/75 e 220/76 do sistema LANDSAT, e a cena de órbita T23KKR do sistema SENTINEL-2. O perímetro da área de estudo abrange a totalidade do território dos municípios de Rio Claro, Araras, Leme, Corumbataí, Itirapina, Ipeúna, Charqueada, Santa Gertrudes, Cordeirópolis, Analândia, Santa Cruz da Conceição, Pirassununga, Santa Cruz das Palmeiras, Porto Ferreira, Conchal e Descalvado. Considerando as limitações impostas pela crise sanitária provocada pela Pandemia de Covid-19, não foram realizados os trabalhos de campo necessários para obtenção de dados de verdade terrestre para validação do processo de classificação. Neste sentido, as amostras de validação do processo de classificação foram selecionadas a partir de composições RGB das imagens dos sensores OLI e MSI.

A partir das composições RGB das imagens multiespectrais, foram selecionadas 7 classes para classificação do uso e cobertura da terra. Dentre essas classes, a vegetação foi categorizada em quatro sub classes:

- a) Vegetação natural;
- b) Pastagem;
- c) Lavoura de ciclo anual;
- d) Lavoura de ciclo perene.

As classes de uso e cobertura da terra com características espectrais distintas foram:

- a) Água;
- b) Solo exposto;
- c) Uso urbano.

O procedimento seguinte foi criação das variáveis que contém as amostras dos pixels selecionados para fins de treinamento do classificador e validação dos dados gerados pela classificação. No ambiente API do GEE foram criadas as variáveis relacionadas às categorias de uso e cobertura da terra já previamente definidas e, partir de composições RGB feitas a partir das bandas dos sensores OLI e MSI, foram selecionadas as amostras para o treinamento e validação do processo de classificação. Buscando-se fornecer ao classificador uma ampla variedade de dados de treinamento, foram selecionadas 200 amostras de cada uma das 7 categorias de uso e cobertura da terra, gerando um total de 1400 amostras de treinamento. Deste universo, 70% das amostras foram

utilizada para fins de treinamento de algoritmo, e 30% usados para a validação do processo de classificação.

Após a definição das classes de uso e cobertura da terra, a área de estudo e as amostras de treinamento e validação do processo de classificação, foi selecionada a dimensão temporal das séries de imagens que foram classificadas. Juntamente com este processo, aplicou-se filtros aos metadados das imagens visando eliminar áreas com cobertura excessiva de nuvens a partir de um limiar de cobertura de nuvens inferior a 20% em cada imagem. A seguir, definem-se os classificadores e os parâmetros para os testes de validação do processo de classificação.

Novamente, através da interface do GEE foram inseridos os algoritmos de classificação e validação, sendo selecionado o algoritmo random forest e estabelecendo as 7 classes de uso e cobertura da terra como dados de entrada no modelo. O próximo passo consiste no processo de classificação, que é conduzida por uma função estabelecida na interface do GEE, que considera as variáveis estabelecidas nos códigos anteriores. Com base nos resultados do processo de classificação, foram estabelecidas as funções de validação do processo de classificação, obtendo-se como resultados a matriz de confusão, a acurácia geral da validação e o índice Kappa, as acurácias do produtor e do consumidor. Por fim, são estabelecidos os comandos para exportação dos resultados no formato “.tif” e edição final dos produtos cartográficos.

4.1 Sistemas Sensores de média resolução espacial

O sensoriamento remoto consiste na utilização de sensores e técnicas de observação e coleta de informações sobre os mais variados objetos e fenômenos, sem que ocorra contato físico entre o fenômeno e o sensor, de forma que os dados e informações são coletados e registrados através medições nas flutuações do campo eletromagnético que são decorrentes da interação entre a radiação eletromagnética e a matéria, que por sua vez consiste nos alvos da superfície terrestre: vegetação, solos e rochas, a água em seus três estados físicos, e os gases e aerossóis em suspensão na atmosfera (LONGLAY, 2012, p. 312). Conforme exposto anteriormente, esta pesquisa analisou o uso e cobertura da terra a partir de dados de imagens orbitais de sensores óticos multiespectrais, com disponibilidade de imagens para o território brasileiro e com regularidade de resolução temporal. Para cumprir este objetivo, foram selecionados os seguintes sistemas/sensores: LANDSAT 8/OLI, e SENTINEL 2/MSI, conforme demonstrado na tabela 2.

Tabela 2 – Características dos sensores OLI e MSI

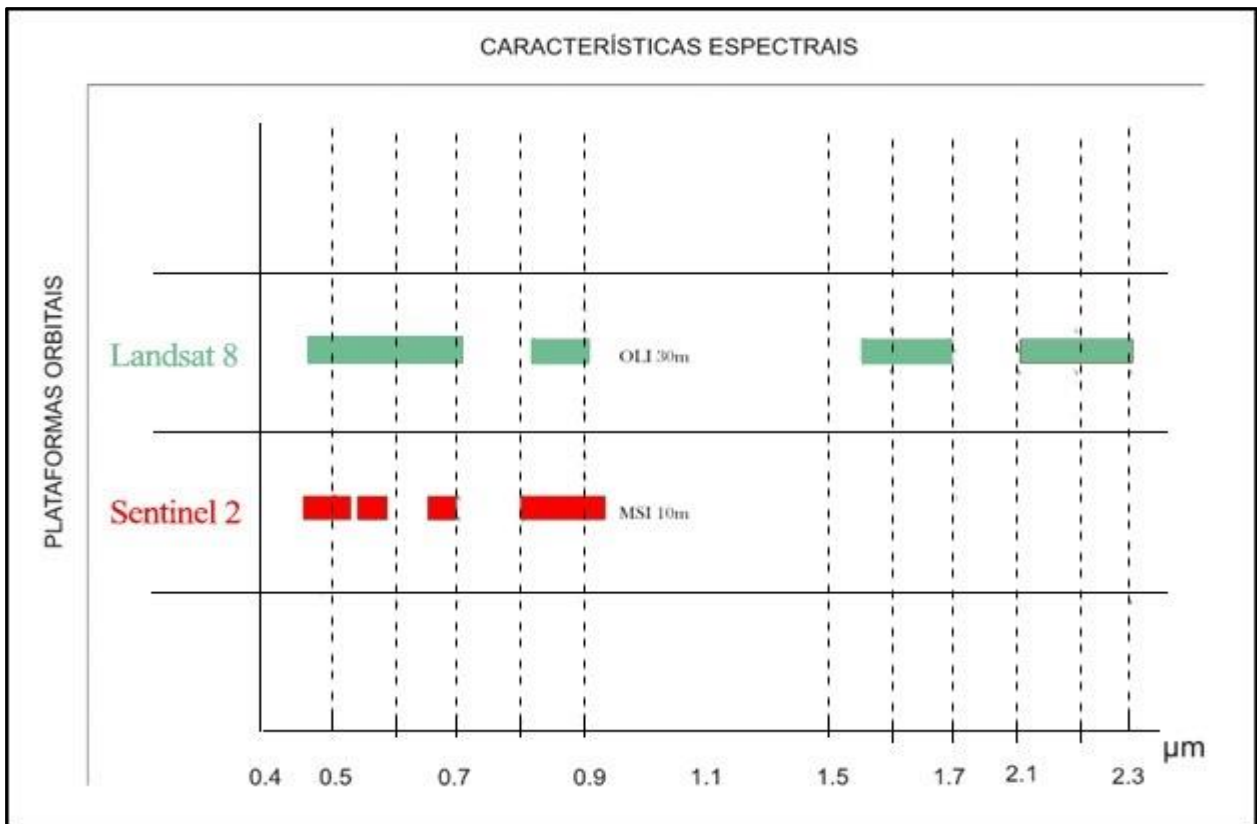
Satélite/Sensor	Resolução espacial (m)	Resolução temporal (dias)	Resolução Espectral ⁴	Resolução radiométrica (bits)	Nível de processamento ¹
LANDSAT 8/ OLI	30	16	7	12	Level 1T ²
SENTINEL / MSI	10	(07, 10 ,20)	4	12	Level 1T ²

¹Nível de processamento das imagens fornecidas; ²Correção radiométrica sistemática e acurácia geométrica por meio de pontos de controle em solo e um modelo digital de elevação; ³Imagem georreferenciada acompanhada de RPC (Rational Polynomial Coefficient) para realização de correção geométrica; ⁴ Informadas apenas as bandas utilizadas na pesquisa.

Fonte: Elaborado pelo Autor.

Os sistemas de sensoriamento remoto selecionados apresentam tecnologias consolidadas em décadas de desenvolvimento, com histórico de evolução e aprimoramento de sistemas sensores ópticos que garantem a aplicação de seus produtos para finalidades de mapeamentos de alvos terrestres. Com base na figura 4, é possível observar que há similaridade na distribuição e largura das bandas espectrais dos sensores sugeridos para análise, principalmente nas características das bandas referentes ao comprimento do Infravermelho próximo (0,7 a 0,9 μm) e Vermelho (0,6 a 0,7 μm), que contém as principais informações espectrais para os estudos de vegetação, as quais foram aplicadas nesta pesquisa. Em termos da resolução temporal adotada, foi utilizado o maior número de imagens disponíveis para a área de estudo, buscando a maior frequência de imageamento possível sem a cobertura de nuvens. A figura 4 faz um comparativo com a largura das bandas de coleta de dados dos sensores OLI e MSI, de comprimentos de onda que vão do espectro visível até o infra vermelho de ondas curtas do sistema LANDSAT 8.

Figura 4: Características espectrais dos sensores OLI e MSI.



FONTE: Elaborado pelo autor

4.2 Sistema LANDSAT 8

Os satélites e sensores do sistema LANDSAT são responsáveis pelas maiores séries temporais de sensoriamento remoto por dados orbitais, entrando em operação em julho de 1972 com o satélite ERTS-1, e permanecendo em operação até hoje com os Satélites LANDSAT 8 e LANDSAT 9, sendo este último colocado em órbita em 23 de setembro de 2021. O satélite LANDSAT 8 carrega os sensores OLI (Operational Land Imager), e TIRS (Thermal Infrared Sensor). Os dados utilizados nesta pesquisa são provenientes do sensor OLI, que opera com onze bandas espectrais a partir do espectro da luz visível, até o infravermelho de ondas curtas.

De acordo com Ihlen (2019, p.10) O sistema LANDSAT 8 possui uma frequência de revisita de 16 dias, no entanto, a partir da operacionalização do sistema LANDSAT 9, a frequência de revisita passará a ser de 8 dias. A resolução radiométrica do sensor OLI é de 12 bits, o que confere ao instrumento a habilidade de registrar 4096 intensidades de sinal de retorno, codificados em níveis de cinza nas bandas B1 (0,43 – 0,45 μm), B2 (0,45 – 0,51 μm), B3 (0,53 – 0,59 μm), B4

(0,64 – 0,67 μm) B5 (0,85 – 0,88 μm), B6 (1,57 – 1,65 μm), B7 (2,11 – 2,29 μm) e B9 (1,36 – 1,38 μm) com 30 metros de resolução espacial; as bandas B10 (10,6 – 11,19 μm) e B11 (11,5 – 12,51 μm) operam na faixa do infra vermelho termal e possuem resolução espacial de 100 metros. A banda B8 (pancromática 0,5 – 0,68 μm) possui 15 metros de resolução espacial. As dimensões da faixa de imageamento são de 170 km no sentido norte/sul, e 183 km no sentido leste oeste. A tabela 3 apresenta as características dos sensores do sistema LANDSAT 8.

Tabela 3 - Características do sensor OLI

Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Radiométrica	Área Imageada (km)
B1 – Azul Costeiro	0,43 – 0,45	30	12	170 x 183
B2 – Azul	0,45 – 0,51	30	12	170 x 183
B3 – Verde	0,53 – 0,59	30	12	170 x 183
B4 – Vermelho	0,64 – 0,67	30	12	170 x 183
B5 – Infra Vermelho Próximo	0,85 – 0,88	30	12	170 x 183
B6 - Infra Vermelho Médio	1,57 – 1,65	30	12	170 x 183
B7 – Infra Vermelho Médio	2,11 – 2,29	30	12	170 x 183
B8 – Pancromática	0,50 – 1,38	15	12	170 x 183
B9 - Cirrus	1,36 – 1,38	30	12	170 x 183

Fonte: Elaborado pelo Autor.

Atualmente o programa LANDSAT é uma parceria entre o USGS (United States Geological Survey) e a NASA (National Aeronautics and Space Administration) que fornece os produtos nos níveis de processamento de reflectância de superfície, reflectância de topo da atmosfera. Nesta pesquisa foram utilizadas imagens geradas a partir do algoritmo Land Surface Reflectance Code (LaSRC). De acordo com Vermote *et al.* (2016, p. 45) a reflectância de superfície é obtida a partir da correção da interferência dos gases de topo da atmosfera, sendo corrigidos os efeitos de dispersão e absorção temporal, espacial e espectral dos gases atmosféricos e aerossóis. Os produtos de reflectância de superfície são necessários para monitorar a superfície terrestre de forma confiável. Por esta razão, eles são usados para gerar a séries temporais, uma vez que eliminam as

interferências causadas pela variação das condições da atmosfera, gerando um sinal de retorno por parte do alvo com maior fidelidade às suas reais características espectrais.

4.3 Sistema SENTINEL-2

Os satélites de observação dos recursos terrestres da série SENTINEL fazem parte da missão de observação da Terra do Programa Copernicus, de responsabilidade da Agência Espacial Europeia (ESA) em cooperação com os países membros da União Europeia. A missão SENTINEL é composta por seis distintos satélites, cada um com um objetivo específico:

- a). SENTINEL 1: Composta por dois satélites com órbita polar (SENTINEL 1A e SENTINEL 1B) que operam na Banda C do Sistema Radar de Abertura Sintética (SAR). O objetivo da missão é coletar informações dos recursos terrestres de forma ininterrupta, uma vez que os radares de abertura sintética são sistemas sensores ativos que operam na faixa das micro-ondas do espectro eletromagnético, o que lhes garante a habilidade de fazer imageamentos por entre as nuvens durante o dia e a noite;
- b). SENTINEL 2: a missão SENTINEL 2 é composta por dois satélites ópticos de órbita polar (SENTINEL 2A e SENTINEL 2B) que registram a radiação eletromagnética refletida pela Terra em treze bandas espectrais, na faixa da luz visível até o infravermelho de ondas curtas;
- c). SENTINEL 3: a missão SENTINEL-3 tem por objetivo coletar informações sobre os oceanos e a superfície terrestre. É composta por dois satélites que operam o instrumento OLCI (Ocean and Land Colour Instrument), com 21 bandas espectrais cujo principal objetivo consiste em medir a temperatura da superfície terrestre e dos oceanos, e também fornecer dados sobre a topografia da superfície e a cor dos oceanos.;
- d). SENTINEL 4: a missão SENTINEL 4 tem por objetivo monitorar a composição dos gases da atmosfera a partir da plataforma orbital geoestacionária.
- e). SENTINEL 5: tem por objetivo monitorar a composição da atmosfera terrestre, com foco na qualidade do ar e na relação entre a composição dos gases atmosféricos e o clima.
- f). SENTINEL 6: é composto por plataforma de órbita polar cujo objetivo consiste em medir flutuações no nível dos oceanos, altura das ondas e velocidade do vento

Os dados utilizados nesta pesquisa são provenientes da missão SENTINEL 2, que é composta por dois satélites que carregam a bordo o sensor MSI, que coleta informações em treze bandas espectrais a partir da fronteira do ultra violeta com a luz visível, até o infravermelho de ondas

curtas. O sistema SENTINEL 2 possui uma frequência de revisita de 5 dias e a resolução radiométrica é de 12 bits, o que confere ao instrumento a habilidade de registrar 4096 intensidades de sinal de retorno, codificados em níveis de cinza nos pixels das imagens. Nesta pesquisa foram utilizadas as bandas B2 (0,47 – 0,52 μm), B3 (0,54 – 0,57 μm), B4 (0,65 – 0,68 μm) e B8 (0,74 – 0,89 μm) com 10 metros de resolução espacial; e as bandas B5 (0,69 – 0,71 μm), B6 (0,73 – 0,74 μm), B7 (0,77 – 0,79 μm) e B8A (0,85 – 0,87 μm) com 20 metros de resolução espacial. A tabela 4 resume as características do sensor MSI.

Tabela 4 - Características do sensor MSI

Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Radiométrica	Área Imageada (km)
B1 – Aerossol	0,43 – 0,45	60	12	110 x 110
B2 – Azul	0,47 – 0,52	10	12	110 x 110
B3 – Verde	0,54 – 0,57	10	12	110 x 110
B4 – Vermelho	0,65 – 0,68	10	12	110 x 110
B5 – Red Edge 1	0,69 – 0,71	20	12	110 x 110
B6 - Red Edge 2	0,73 – 0,74	20	12	110 x 110
B7 – Red Edge 3	0,77 – 0,79	20	12	110 x 110
B8 – NIR Infrared	0,74 – 0,89	10	12	110 x 110
B8A - Red Edge 4	0,85 – 0,87	20	12	110 x 110
B9 – Vapor d'água	0,93 – 0,95	60	12	110 x 110
B10 – Cirrus	1,36 – 1,39	60	12	110 x 110
B11 – SWIR 1	1,56 – 1,65	20	12	110 x 110
B12 – SWIR 2	2,1 – 2,28	20	12	110 x 110

Fonte: Elaborado pelo Autor.

4.4 Google Earth Engine

O Google Earth Engine é uma Plataforma de geoprocessamento baseada no conceito de “Cloud-based computing” (computação na nuvem), que consiste em uma nova tecnologia de processamento e armazenamento de dados que elimina a necessidade física de equipamentos de grande capacidade de processamento de dados. A partir do fornecimento desta tecnologia de forma gratuita, o sistema GEE ampliou as possibilidades de análise para toda comunidade científica e de

usuários de dados espaciais. De acordo com Gorelick et al. (2017), a arquitetura de dados e infraestrutura operacional do GEE permite a elaboração de análises geoespaciais em escala planetária, de forma a aplicar a massiva capacidade de computação da Google na resolução de problemas de relevância social como monitoramento de secas, monitoramento e da perda de vegetação natural, manejo de recursos hídricos, monitoramento climático e as mais diversas aplicações no campo da agricultura e segurança alimentar.

O uso das ferramentas do GEE tem se tornado cada vez mais popular, fornecendo a toda comunidade científica acesso simplificado aos dados dos sistemas de monitoramento global através dos satélites de recursos terrestres, que incluem dados de sensores ópticos e de radar, mapas de uso da terra, dados de monitoramento de variáveis ambientais (incluem-se como exemplos séries históricas de dados climatológicos e hidrológicos), mapas topográficos e dados socioespaciais. A biblioteca de imagens é atualizada com aproximadamente 6000 cenas por dia, com uma latência de cerca de 24hs entre a aquisição do dado e sua publicação na plataforma (GOLEIK et al, 2017). A tabela 3 apresenta os dados mais utilizados da plataforma GEE.

Tabela 5 - Principais dados disponíveis nas bibliotecas do Google Earth Engine

Sistema de Observação de Recursos Terrestres	Resolução Espacial	Resolução Temporal	Início da série de dados	Escala de abrangência
LANDSAT				
LANDSAT 8 OLI/TIRS	30 metros	16 dias	2013– Presente	Global
LANDSAT 7 ETM +	30 metros	16 dias	2000– 2017	Global
LANDSAT 5 TM	30 metros	16 dias	1984–2012	Global
LANDSAT 4–8 reflectância de superfície	30 metros	16 dias	1984– Presente	Global
SENTINEL				
SENTINEL 1 A/B ground range detected - SAR	10 m	6 dias	2014– Presente	Global
SENTINEL 2A e 2B MSI – reflectâncias de topo da atmosfera	10/20 m	10 dias	2015– Presente	Global
SENTINEL 2A e 2B MSI – reflectâncias de superfície	10/20 m	10 dias	2015–Presente	Global
MODIS				
MOD08 atmosfera	1°	Diária	2000– Presente	Global

Sistema de Observação de Recursos Terrestres	Resolução Espacial	Resolução Temporal	Início da série de dados	Escala de abrangência
MOD09 reflectância de superfície	500 m	1 - 8 dias	2000– Presente	Global
MOD10 cobertura de neve	500 m	1 dia	2000– Presente	Global
MOD11 temperatura e emissividade	1000 m	1- 8 dias	2000– Presente	Global
MCD12 cobertura da Terra	500 m	Anual	2000– Presente	Global
MOD13 Índices de Vegetação	500/250 m	16 dias	2000– Presente	Global
MOD14 Anomalias termais	1000 m	8 dias	2000– Presente	Global
MCD15 Índice de área foliar	500 m	4 dias	2000– Presente	Global
MOD17 Prod. primária bruta	500 m	8 dias	2000– Presente	Global
MCD43 BRDF-reflec. ajustada	1000/500 m	8 - 16 dias	2000– Presente	Global
MOD44 cobertura vegetal	250 m	Anual	2000– Presente	Global
MCD45 anomalias termais	500 m	30 dias	2000–Presente	Global
ASTER				
L1 T radiance	15/30/90 m	1 dia	2000–Presente	Global
Global emissivity	100 m	Variável	2000–2010	Global
Outros Produtos				
PROBA-V Reflectância de topo de copas	100/300 m	2 dias	2013–Presente	Global
EO-1 hyperion hyperspectral radiance	30 m	Programada no alvo	2001–Presente	Global
DMSP-OLS nighttime lights	1 km	Anual	1992–2013	Global
USDA NAIP aerial imagery	1 m	Semestral	2003–2015	EUA
Topografia				
Shuttle Radar Topography Mission	30 m	Dataset único	2000	60°N–54°S
USGS National Elevation Dataset	10 m	Dataset único	Múltiplas datas	EUA
USGS GMTED2010	7.5"	Dataset único	Múltiplas datas	83°N–57°S
GTOPO30	30"	Dataset único	Múltiplas datas	Global
ETOPO1	1'	Dataset único	Múltiplas datas	Global
Cobertura da Terra				
GlobCover	300 m	Não periódico	2009	90°N–65°S

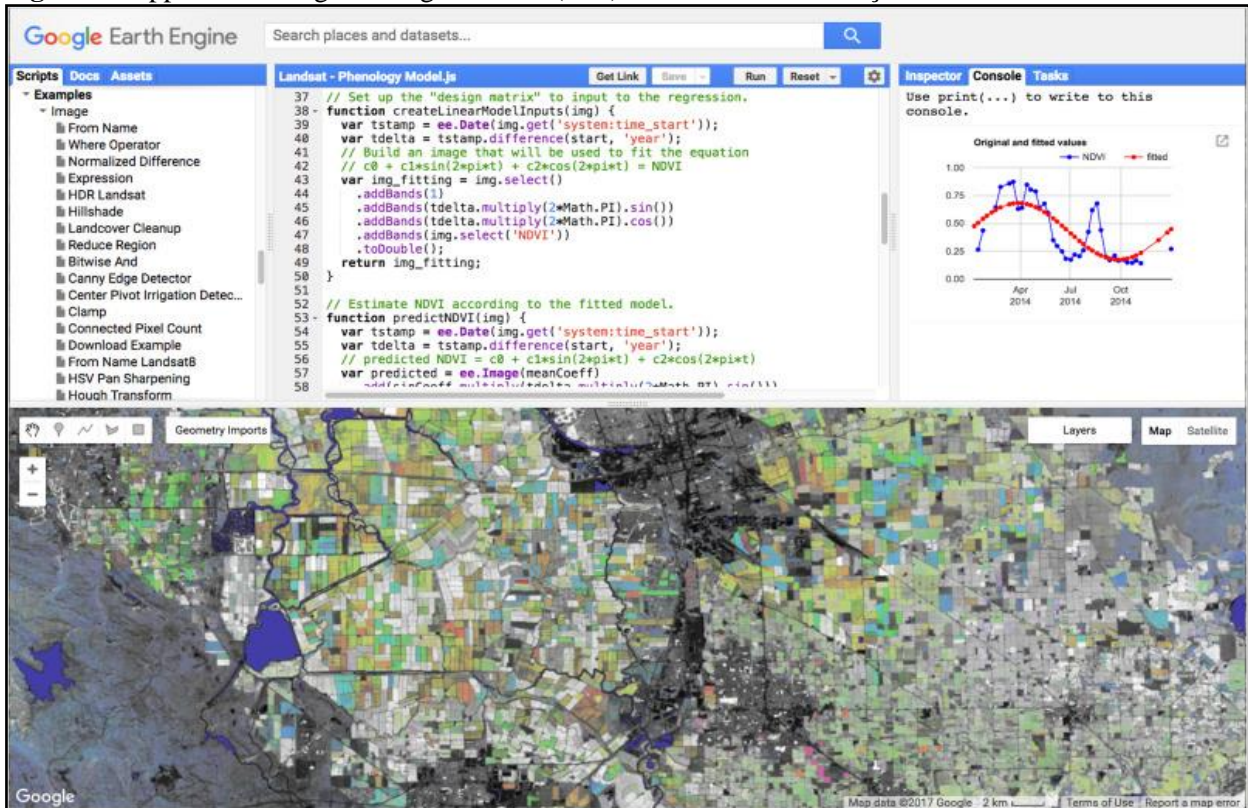
Sistema de Observação de Recursos Terrestres	Resolução Espacial	Resolução Temporal	Início da série de dados	Escala de abrangência
USGS Dataset de Cobertura da Terra	30 m	Não periódico	1992–2011	EUA
UMD mudanças na cobertura florestal global	30 m	Anual	2000–2014	80°N–57°S
JRC superfície de água global	30 m	Mensal	1984–2015	78°N–60°S
GLCF cobertura global de árvores	30 m	5 anos	2000–2010	Global
USDA NASS Mapa de cultivos agrícolas	30 m	Anual	1997–2015	EUA
Hidrometeorologia				
Índices de Precipitação Global	6'	3 horas	2014– Presente	Global
TRMM 3B42 precipitação	15'	3 horas	1998–2015	50°N–50°S
CHIRPS precipitação	3'	5 dias	1981– Presente	50°N–50°S
NLDAS-2	7.5'	1 hora	1979– Presente	América Norte
GLDAS-2	15'	3 horas	1948–2010	Global
NCEP reanalysis	2.5°	6 horas	1948– Presente	Global
ORNL DAYMET weather	1 km	Anual	1980– Presente	América do Norte
GRIDMET	4 km	1 dia	1979– Presente	EUA
NCEP global forecast system	15'	6 horas	2015– Presente	Global
NCEP climate forecast system	12'	6 horas	1979–Presente	Global
WorldClim	30"	12 imagens	1960–1990	Global
NEX downscaled climate projections	1 km	1 dia	1950–2099	América do Norte
Sócio-espacial				
WorldPop	100 m	5 anos	Multiplas datas	Global
GPWv4	30"	5 anos	2000–2020	85°N–60°S

FONTE: Adaptado de GOLEICK *et al.*, 2017.

Estes dados são processados através bibliotecas com centenas de funções que variam desde simples cálculos matemáticos, até complexos algoritmos de aprendizado de máquinas e processadores de imagens. A entrada dos comandos e a visualização dos resultados são feitos através “Application Programming Interface” (API) em um navegador de internet, por onde são

inseridas linhas de códigos e comandos de programação nas linguagens Python e JavaScript. A figura 5 demonstra um exemplo de aplicação dos scripts e a visualização dos resultados através de gráficos e imagens projetadas através do API do GEE.

Figura 5: Application Programming Interface (API) – entrada e visualização de dados no GEE.



Fonte: Goleick *et al.*, 2017.

4.5 Classificação supervisionada através do algoritmo Random Forest

A aplicação de algoritmos do tipo árvore de decisão em trabalhos de classificação do uso e cobertura da terra têm gerado resultados consistentes, principalmente devido às técnicas de aprendizado de máquina que estes algoritmos levam em conta. Conforme descrito por Latorre *et al.*, (2007, p.67), a árvore de decisão é composta pelas seguintes unidades:

- um nó raiz formado a partir de todos os dados;
- um conjunto hierárquico de nós internos denominados partições responsáveis pela tomada de decisão, utilizando critérios, que define o próximo nó descendente ou filho;
- nós terminais chamados de folhas caracterizados por não possuírem nó descendente.

Nesta pesquisa foi utilizado o método de classificação supervisionada pixel a pixel, onde o analista, através de seu conhecimento prévio, seleciona as amostras de pixels e os associa a uma determinada classe de uso e cobertura da terra. Nesta etapa foram definidas as 7 classes de uso e cobertura da terra classificadas neste trabalho: água, vegetação natural, pastagens, lavouras de ciclo anual, lavouras de ciclo perene, áreas urbanas. Após a definição das classes, procedeu-se a etapa de coleta das amostras para os processos de treinamento e validação do classificador. O processo de seleção de amostras foi feito partir de composições RGB de imagens dos sensores OLI e MSI.

O classificador utilizado nesta pesquisa foi do tipo árvore de decisão que, entre outros modelos, inclui o Random Forest, um algoritmo de aprendizado de máquina que utiliza um conjunto de árvores aleatórias para realizar uma previsão. Conforme Souza Jr *et al.* (2020, p. 14), o modelo Random Forest opera a partir de um conjunto de dados pelos quais são criadas árvores de decisão, que são alimentadas pelos valores de reflectância dos pixels das imagens. Os dados de treinamento das classes de uso compõem, cada um, uma árvore de decisão de forma que para cada árvore irá apresentar um resultado diferente para classificar o pixel.

4.6 Testes de validação do mapeamento

Os procedimentos para seleção de amostras, treinamento do classificador e validação da classificação são descritos por Congalton e Green (2009), e incluem como principais parâmetros para avaliação da qualidade da classificação o índice kappa, que avalia a concordância entre os pixels classificados e os pixels utilizados como amostras de referência para as classes de uso e cobertura da terra. O índice de acurácia do consumidor e o índice de acurácia do produtor, estão relacionados com os erros de omissão e inclusão de pixels em uma determinada classe de uso e cobertura da terra. Este processo teve por objetivo estabelecer quais classes apresentam os melhores resultados e onde ocorrem as inconsistências do mapeamento.

Conforme Moretin e Bussad (2019), a matriz de confusão é utilizada para avaliar a exatidão do processo de classificação através da comparação entre os resultados obtidos a partir da amostra de treinamento, com os dados das amostras de referência. A partir da matriz de confusão são calculados os valores de acurácia que irá ajudar na compreensão do comportamento do algoritmo e as inconsistências que ocorrem entre as classes. Na interpretação dos dados, a diagonal da matriz indica os valores classificados corretamente, sendo a partir dela calculada a Acurácia Global, que relaciona o somatório dos valores classificados corretamente dentro de cada classe, com o número

total de pontos estabelecidos na amostra de validação.

4.7 Índice NDVI

Entre as principais contribuições dos dados de sensoriamento remoto para objetivos e aplicações em agricultura, situam-se aquelas relacionadas com o monitoramento e estimativa de parâmetros biofísicos das culturas agrícolas (FORMAGGIO e SANCHES, 2017). Neste sentido, os índices de vegetação (IVs), representam métodos fundamentais para caracterização da dinâmica temporal e do vigor da vegetação agrícola.

Imagens obtidas para indicação do índice de vegetação têm sido utilizadas na caracterização da cobertura vegetal e seu vigor de fitomassa. Segundo Moreira e Shimabukuro (2004), os índices de vegetação começaram a ser pesquisados no final da década de 60 por Jordan (1969) e estão todos apoiados na diferença de resposta da vegetação existente entre a faixa espectral de 0,4 a 0,7 μm , (B, G e R) e a faixa de 0,7 a 0,9 μm (IR). Estas larguras de bandas são adotadas pela maioria dos satélites de recursos naturais, permitindo que os índices de vegetação sejam aplicados na extração de informações biofísicas das formações vegetais.

Destaca-se que a reflectância que deve ser utilizada nessa técnica é a reflectância na superfície da terra, ou seja, é fundamental se corrigir os efeitos causados pela atmosfera em cada uma das bandas. A biblioteca de imagens do GEE possui as imagens dos sensores OLI e MSI processadas em nível de reflectância de superfície, constituindo-se em uma vantagem em relação aos SIGs convencionais que demandam grande capacidade de processamento de dados no processo de correção dos efeitos da atmosfera.

Uma das grandes vantagens de se utilizar a razão entre bandas é que não é preciso corrigir os efeitos causados pela topografia, pois, sendo esse constante para todas as bandas, é anulado. A finalidade desse procedimento é destacar a diferença de resposta espectral existente entre alvos como solo, rocha e vegetação. A partir da razão entre bandas, muitos índices foram criados para diversas finalidades. Com a finalidade de estudar a vegetação, o índice mais o NDVI (Normalized Difference Vegetation Index - equação 01), que tem como objetivo amenizar a interferência do solo, a influência atmosférica e as variações zenitais do sol, sendo definido por:

$$\text{NDVI} = \frac{(\rho_{\text{IVP}} - \rho_{\text{V}})}{(\rho_{\text{IVP}} + \rho_{\text{V}})} \quad (1)$$

Em que:

ρ_{IVP} = reflectância no infravermelho próximo;

ρ_V = é a reflectância no vermelho.

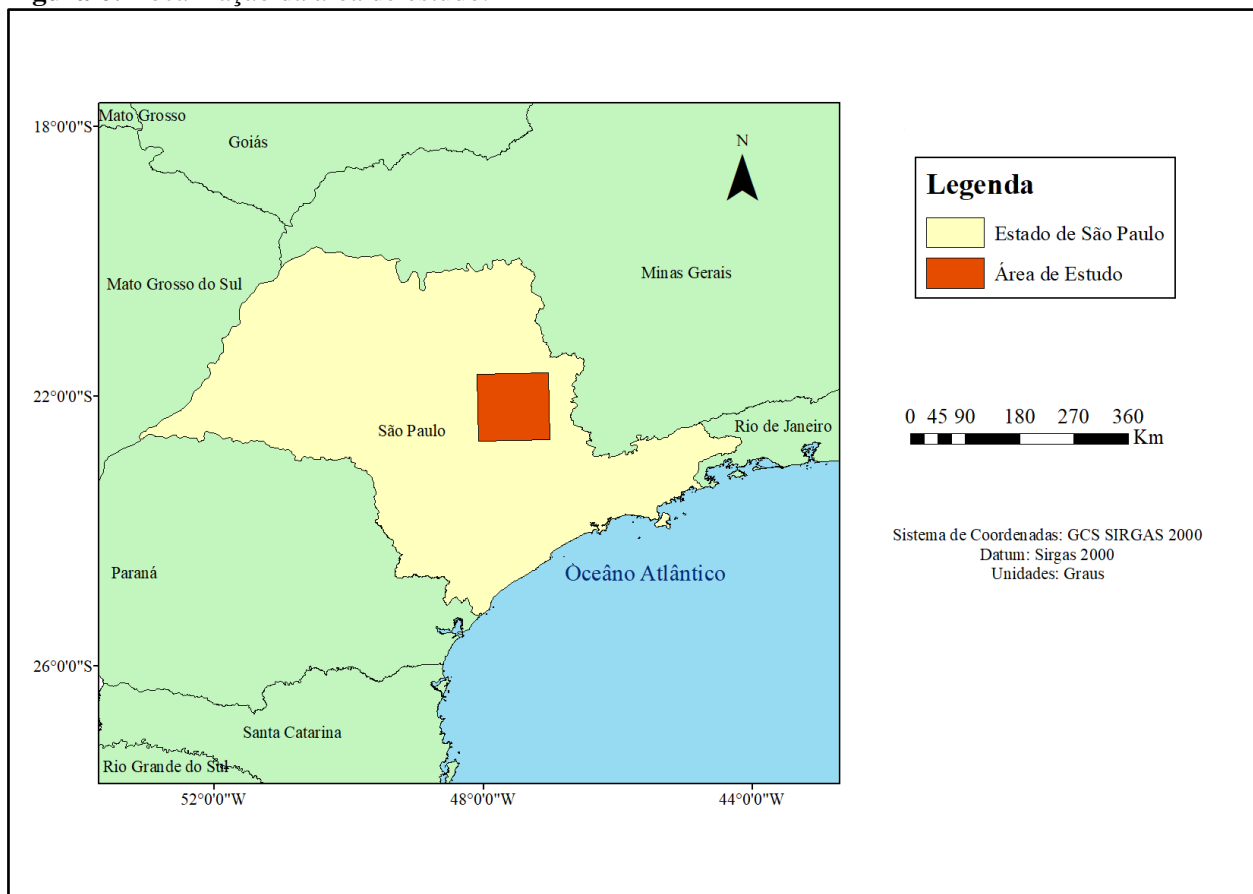
4.8 Trabalho de campo

Nos trabalhos de mapeamento e monitoramento do uso e cobertura da terra, os trabalhos de campo têm por finalidade validar o processo de classificação através do cruzamento dos dados de campo, também conhecidos como verdade terrestre, com os dados obtidos no processo de classificação do uso e cobertura da terra. Nesta pesquisa os trabalhos de campo tiveram a finalidade de explorar a área de estudo, buscando identificar os cultivos agrícolas para posterior validação dos dados, bem como para analisar a variação do índice NDVI nos talhões de cultivo agrícola. Originalmente esta pesquisa propunha um trabalho de campo por mês ao longo do ano de 2020, no entanto, as restrições impostas pelo quadro de pandemia de Covid 19 impossibilitaram a realização da maioria dos trabalhos, sendo realizado somente um trabalho de campo no mês de julho de 2020.

5. ÁREA DE ESTUDO

A área de estudo onde foi aplicada a metodologia, corresponde à região Centro Leste do Estado de São Paulo e é um recorte das órbitas 270/75 e 270/76 do sistema LANDSAT8/OLI e da órbita T23KKR do sistema SENTINEL-2/MSI.

Figura 6: Localização da área de estudo.



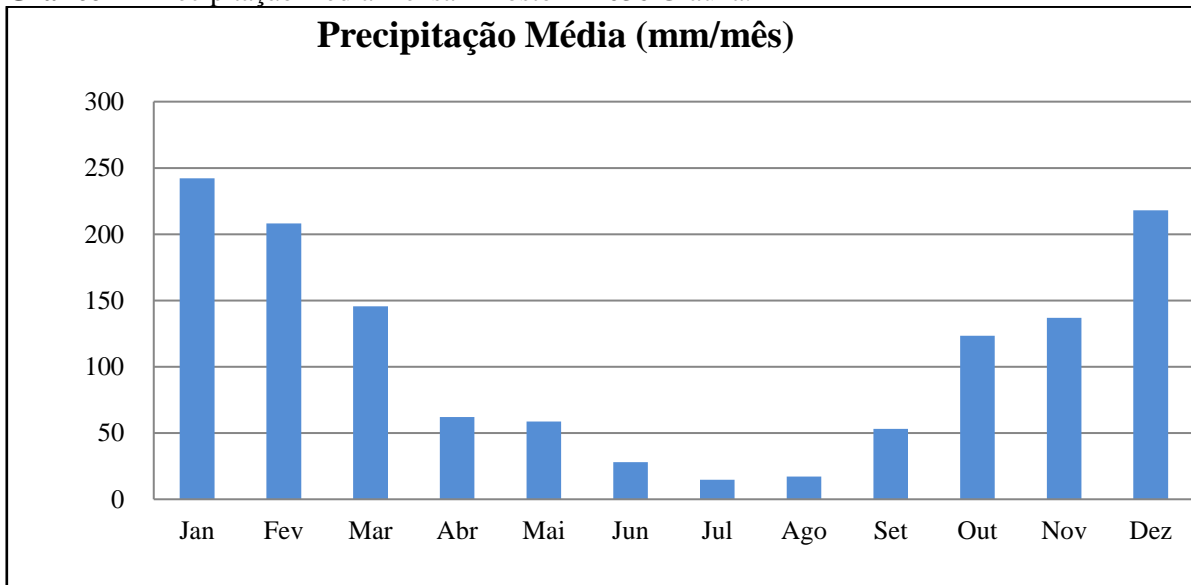
Fonte: Elaborado pelo Autor.

Considerando a distribuição da pluviosidade e as variações de temperatura ao longo do ano, a área de estudo se enquadra no tipo climático CWa, conforme a classificação climática zonal de Köppen, sendo desta forma associada ao Clima subtropical quente e úmido com períodos chuvosos e de seca bem definidos. Durante a Primavera e o Verão predomina o período chuvoso entre os meses de outubro e março. No inverno predomina a estação seca, de abril a setembro. Por se tratar de uma variável de fundamental importância para o estudo das variações do uso e cobertura da terra, foram levantados dados dos postos pluviométricos situados na área de estudo. Os dados foram obtidos através do banco de dados do Departamento de Águas e Energia Elétrica do Estado de São Paulo (DAEE) e a partir de registros de observações meteorológicas de superfície feitas pelo Centro

de Análise e Planejamento Ambiental (CEAPLA/IGCE – Unesp Rio Claro). Os postos pluviométricos do DAEE selecionados são de prefixo D4-036, situado no município de Itirapina – SP sob as coordenadas geográficas 22°18' de latitude sul e 47°45' de longitude oeste, e o posto D4-074, situado no município de Ipeúna - SP sob as coordenadas geográficas 22°16' latitude sul e 47°46' longitude oeste. A estação meteorológica do CEAPLA está situada sob as coordenadas 22°23' latitude sul e 47°32' longitude oeste, sendo utilizados dados de pluviosidade, temperaturas máxima e mínima, e umidade relativa do ar.


De acordo com os dados coletados pelo posto D4-036, os maiores valores médios de chuva pertencem aos meses de dezembro e janeiro com 218,1 e 242,075 mm de chuva respectivamente. As médias mínimas mensais pertencem aos meses de julho e agosto com 14,8 e 17,2 mm de chuva respectivamente, conforme o Gráfico 1. A precipitação média anual corresponde a 1448,01 mm de chuva.

Gráfico 1 - Precipitação média mensal - Posto D4-036 Graúna.




Fonte: Elaborado pelo Autor a partir de dados do DAEE.

O Gráfico 2 representa os dados do Posto D4-074, onde os maiores valores médios de chuva são apresentados nos meses de dezembro e janeiro com índices pluviométricos de 279,2 e 240,1 mm respectivamente. Os menores índices de pluviosidade foram registrados nos meses de julho e agosto com índices pluviométricos equivalentes a 39,3 e 32,3 mm respectivamente. A precipitação média anual equivale a 1382,11 mm de chuva.

Gráfico 2 - Precipitação média mensal - Posto D4-074 Ipeúna

Fonte: Elaborado pelo Autor a partir de dados do DAEE.

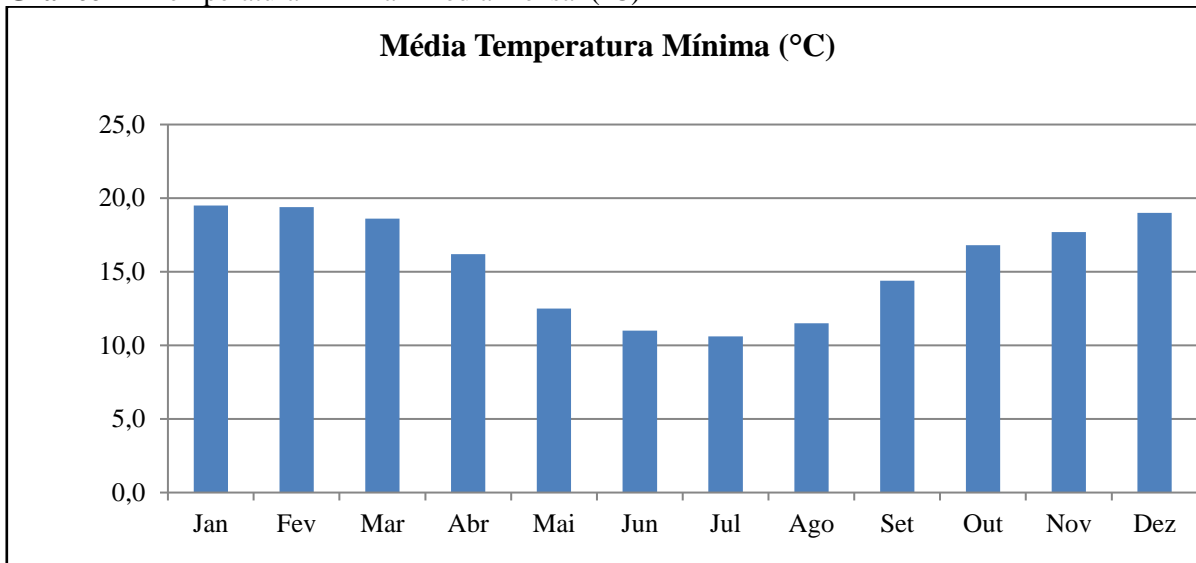
Os dados coletados através da estação meteorológica do CEAPLA foram empregados para descrever o comportamento da temperatura e da umidade relativa do ar. Os maiores valores médios de temperatura correspondem aos meses de fevereiro, com temperatura média de 30,5°C e os meses de março e dezembro, com temperaturas médias de 29,8°C. O mês de junho é o que apresenta a menor temperatura máxima com média de 25,2°C, conforme os dados apresentados no Gráfico 3.

Gráfico 3 - Temperatura máxima - média mensal (°C)

Fonte: Elaborado pelo Autor a partir de dados do CEAPLA – UNESP/RC.


Com relação às temperaturas mínimas, os meses que apresentam as temperaturas mais amenas correspondem aos meses de junho e julho, com médias 11,0°C e 10,6°C respectivamente. Os meses que apresentam as maiores médias de temperaturas mínimas correspondem são janeiro e fevereiro com 19,5°C e 19,4°C, conforme os dados dispostos no Gráfico 4.

Gráfico 4 - Temperatura mínima - média mensal (°C)



Fonte: Elaborado pelo Autor a partir de dados do CEAPLA – UNESP/RC.

O período de maior amplitude térmica na região corresponde aos meses de julho e agosto, com amplitudes médias equivalentes a 15,1°C e 16,3°C respectivamente. Os padrões médios de umidade relativa do ar permanecem quase que homogêneos durante todo o ano com as maiores flutuações ocorrendo nos meses de agosto e setembro que apresentam médias de 56,9% e 57,2% respectivamente, conforme descrito no Gráfico 5. Os baixos índices de umidade relativa do ar correspondem ao fim do período seco, onde devido à grande amplitude térmica e aos padrões de circulação atmosférica predominantes no período, a taxa de umidade pode cair para padrões inferiores a 15% no decorrer do período de 24hs, configurando quadros de estresse hídrico que quedas nos níveis de vigor de fitomassa da cobertura vegetal.

Gráfico 5 - Umidade relativa do ar - média mensal (%)

Fonte: Elaborado pelo Autor a partir de dados do CEAPLA – UNESP/RC.

Os maiores valores médios de chuva pertencem aos meses de dezembro e janeiro com 218,1 e 242,075 mm de chuva respectivamente. As médias mínimas mensais pertencem aos meses de julho e agosto com 14,8 e 17,2 mm de chuva respectivamente. A precipitação média anual corresponde a 1448,01 mm de chuva. Com relação à temperatura, os meses que apresentam as temperaturas mais amenas correspondem aos meses de junho e julho, com temperaturas mínimas médias entre 11,0°C e 10,6°C respectivamente. Os meses com temperaturas mais elevadas correspondem a janeiro e fevereiro com, quando a média das temperaturas máximas são de 19,5°C e 19,4°C respectivamente.

De acordo com o IPT (1981), a área de estudo situa-se na zona de transição entre a Depressão Periférica Paulista e o Planalto Ocidental na porção leste da Bacia Sedimentar do Paraná. A área foi preenchida por sedimentos provenientes de transgressões e regressões marinhas, por sedimentos de áreas mais elevadas, por derrames basálticos e por intrusões de origem vulcânica durante o período compreendido entre o Siluriano (440 – 416 Ma) e o Cretáceo (146 – 65 Ma).

A área de estudo apresenta afloramentos de rochas de idades Paleozóica, compostas por siltitos e argilitos da formação Corumbataí; por rochas de idades Mesozóica das formações Pirambóia, Botucatu, Serra Geral e Itaqueri; e rochas de idades Cenozóica, compostas por depósitos

aluvionais e pelos conglomerados da Formação Rio Claro. De acordo com Penteadó (1976, p. 32) Formação Itaqueri é composta em sua base por folhelhos e conglomerados, sendo sua porção superior composta por arenitos com cimentação argilosa e crostas ferruginosas. Conforme a autora, a Formação Itaqueri ocorre nos reversos das cuestas arenito-basálticas e no alto da serra de Itaqueri, apresentando marcante silificação e estratificação cruzada entre as suas camadas. De acordo com o Instituto de Pesquisas Tecnológicas (IPT, 1981), as rochas da Formação Serra Geral são compostas por derrames de basaltos toleíticos com intercalações de arenitos da Formação Botucatu. Os basaltos apresentam textura afanítica de coloração cinza escura a preta, amigdaloidal no topo dos derrames com desenvolvimento de juntas horizontais e verticais causadas por resfriamento e influencia tectônica onde pode-se verificar a presença de corpos intrusivos compostos por sills e diques de basaltos toleíticos. Os derrames basálticos estão presentes no topo e nos reversos das cuestas arenítico-basálticas e em morros testemunhos próximos das mesmas.

De acordo com o IPT (1981, p. 45), a Formação Botucatu é composta por arenitos de granulação fina a média de coloração vermelha, rosa ou amarela clara. O contato em sua parte superior é caracterizado por interdigitações que recobrem arenitos da mesma natureza da Formação Piramboia. O contato com os basaltos da Formação Serra Geral ocorre de forma difusa e estende-se numa faixa continua às escarpas e serras basálticas.

De acordo com Koffler (1994, p.169), a Formação Pirambóia é constituída por arenitos de coloração avermelhada com intercalação de arenitos finos e médios, possuindo uma fração argilosa em sua parte inferior e siltitos argilosos intercalados por níveis de arenitos, folhelhos e argilitos de coloração que variam entre amarelo claro, roxo, vermelho e verde, característicos de pretéritos ambientes fluviais e planícies de inundação.

De acordo com Landim (1967, p. 31), a Formação Corumbataí é constituída por argilitos de coloração avermelhada e arroxeadas apresentando intercalações de lentes de areníticas de granulação fina e xistos de textura argilosa. As características de sedimentação indicam um ambiente deposicional sobre influências litorâneas num ambiente raso e oxidante. De acordo com Penteadó (1976, p. 37) a Formação Rio Claro é composta por arenitos, seixos e conglomerados de coloração amarela e vermelho claro, mal selecionados e friáveis com alguns pontos de estratificação cruzada. Segundo a autora, a Formação Rio Claro teve sua gênese num ambiente semi-árido de deposição continental de idade Cenozóica.

A área de estudo está situada sobre o domínio geomorfológico da Depressão Periférica

Paulista. De acordo com Almeida (1964, p. 231), a região apresenta características de topografia suave, com a presença de colinas onde predominam interflúvios com áreas de 1 a 4 km², apresentando topos aplainados e vertentes com perfis convexos e retilíneos. O principal padrão de drenagem é a dendrítica, apresentando-se com média e baixa intensidade (IPT, 1981). Segundo relata Penteadó (1976, p.40), a Depressão Periférica é recoberta por uma densa rede de drenagem, apresentando rios consequentes que rompem as estruturas paleozoicas e mesozoicas constituídas pelas formações cuestiformes. De acordo com o IPT (1981), as feições de relevo da Depressão Periférica Paulista são constituídas pelas colinas amplas, colinas médias, morrotes alongados e espigões que se situam em áreas de grandes interflúvios, ou em zonas onde o substrato rochoso possui natureza heterogênea, com predominância de fácies sedimentares e argilosas. De acordo com Almeida (1964, p. 185), os sedimentos que recobrem a zona do médio Tietê sofrem uma grande influência causada pela intrusão de rochas vulcânicas, fato que é refletido na topografia da área, onde também se verificam zonas de falhamento. Desta forma, a interação entre o homem e os elementos abióticos que dominam a área de estudo, é responsável pela construção da paisagem.

6. RESULTADOS E DISCUSSÃO

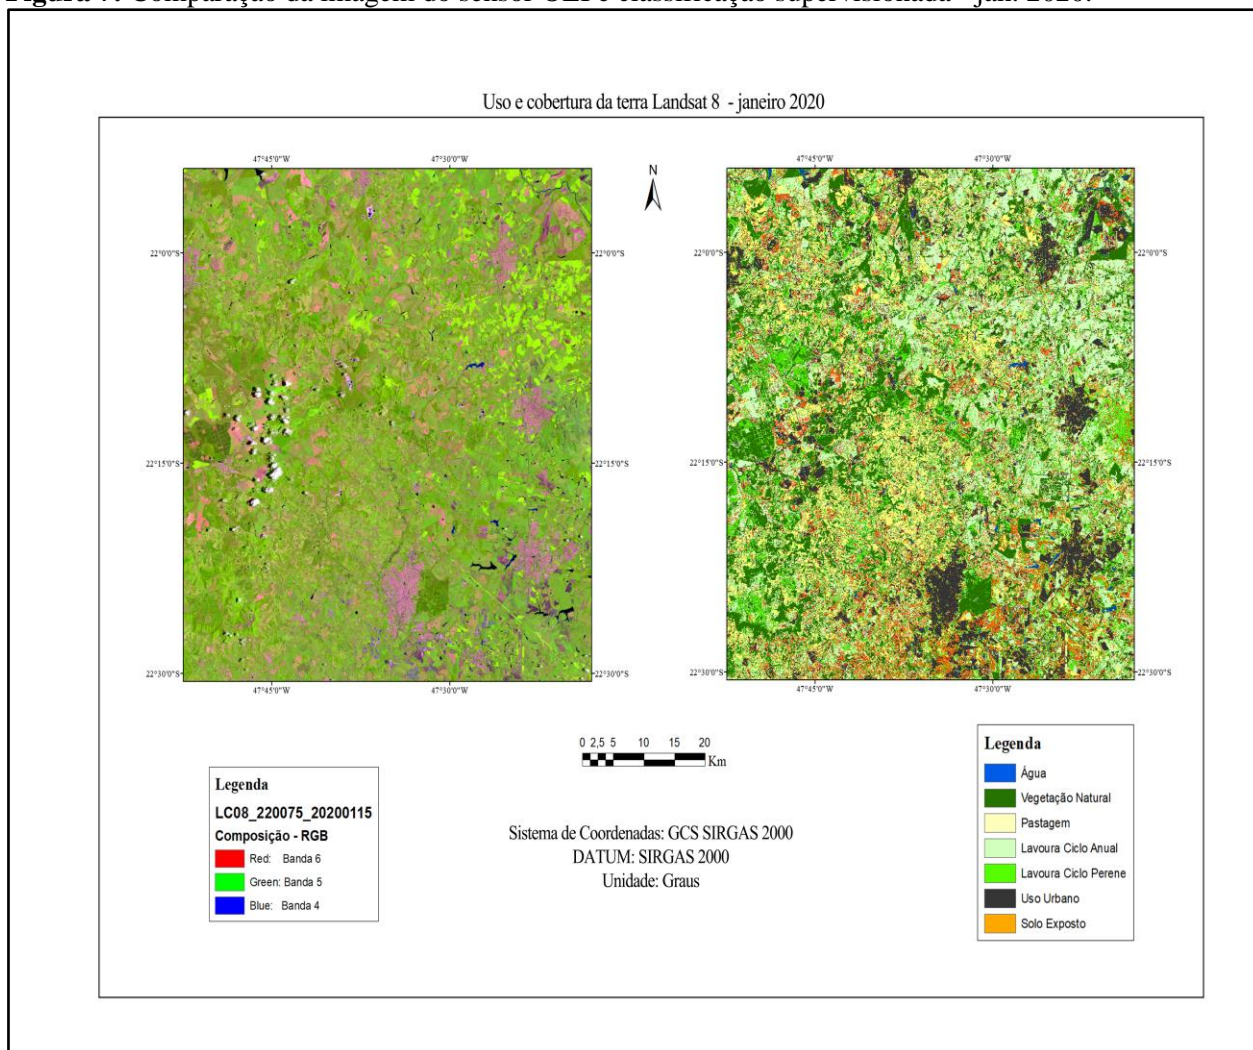
Foi modelado um cenário para cada mês de 2020, de forma a se obter a melhor classificação com a menor interferência de ruídos de nuvens. Os meses com melhores resultados no processo de classificação de imagens do sensor OLI correspondem aos meses de janeiro, abril, agosto, setembro e outubro, onde foi possível obter cenas com menos de 20% de cobertura de nuvens. Nos meses de fevereiro, março, maio, junho, novembro e dezembro, os resultados são inconsistentes dada a cobertura de nuvens.

Os melhores resultados para a classificação das imagens feitas a partir do sensor MSI correspondem aos meses de

6.1 Classificação supervisionada de imagens do sensor OLI – janeiro 2020.

A imagem do mês de janeiro foi coletada no dia 15 de janeiro de 2021 e a classificação do uso da terra foi favorecida pela baixa incidência de nuvens no momento da tomada da cena. Foi utilizado o índice kappa para avaliar a concordância entre os pixels classificados e as amostras de referência. Quanto mais próximo de 1, maior é a eficiência da classificação medida pelo índice kappa, o qual para o processo de classificação supervisionada do mês de janeiro foi de 0,97. O índice de acurácia geral da validação, obtido a partir da diagonal principal da matriz de confusão, indica o somatório de todos os valores que foram classificados corretamente dentro de cada classe de uso e cobertura da terra. Quanto mais próximo de 1 maior é o grau de eficiência medido pelo índice, de forma que para o mês de janeiro a acurácia geral foi de 0,98. O Índice de Acurácia do Consumidor e Índice de Acurácia do Produtor medem quais classes foram melhor discriminadas e quais foram as maiores inconsistências, estando relacionado com os erros de omissão e inclusão, respectivamente. Todas as classes de uso e cobertura da terra analisados apresentaram elevados índices de acurácias do consumidor e do produtor, estando situados acima do patamar de 0,92. A figura 7 é uma comparativo da composição RGB em falsa cor, elaborada a partir das bandas B6 (da imagem do sensor OLI e a imagem classificada.

Figura 7: Comparação da imagem do sensor OLI e classificação supervisionada - jan. 2020.



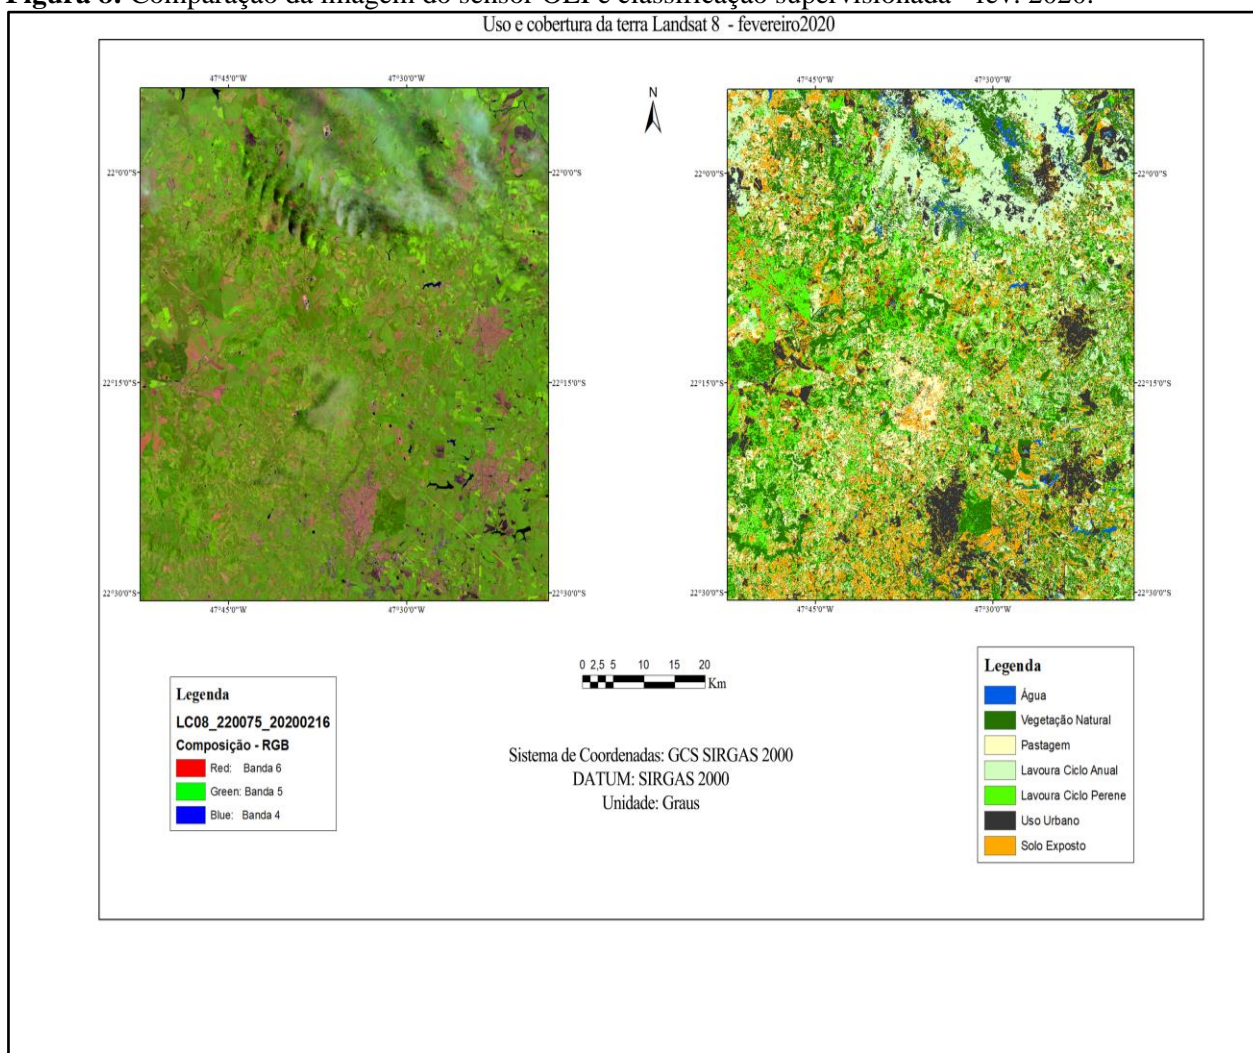
Fonte: Elaborado pelo Autor

6.2 Classificação supervisionada de imagens do sensor OLI – fevereiro 2020.

No mês de fevereiro o processo de classificação foi prejudicado pela excessiva cobertura de nuvens no dia da tomada da imagem em 16 de fevereiro de 2020. O índice kappa e o índice de acurácia geral foram de 0,97 e 0,98 respectivamente. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor foram elevados, apresentando médias de 0,97. Apesar dos elevados

índices de qualidade da classificação, os resultados não são fieis nas porções leste e norte presentes na figura 8.

Figura 8: Comparação da imagem do sensor OLI e classificação supervisionada - fev. 2020.

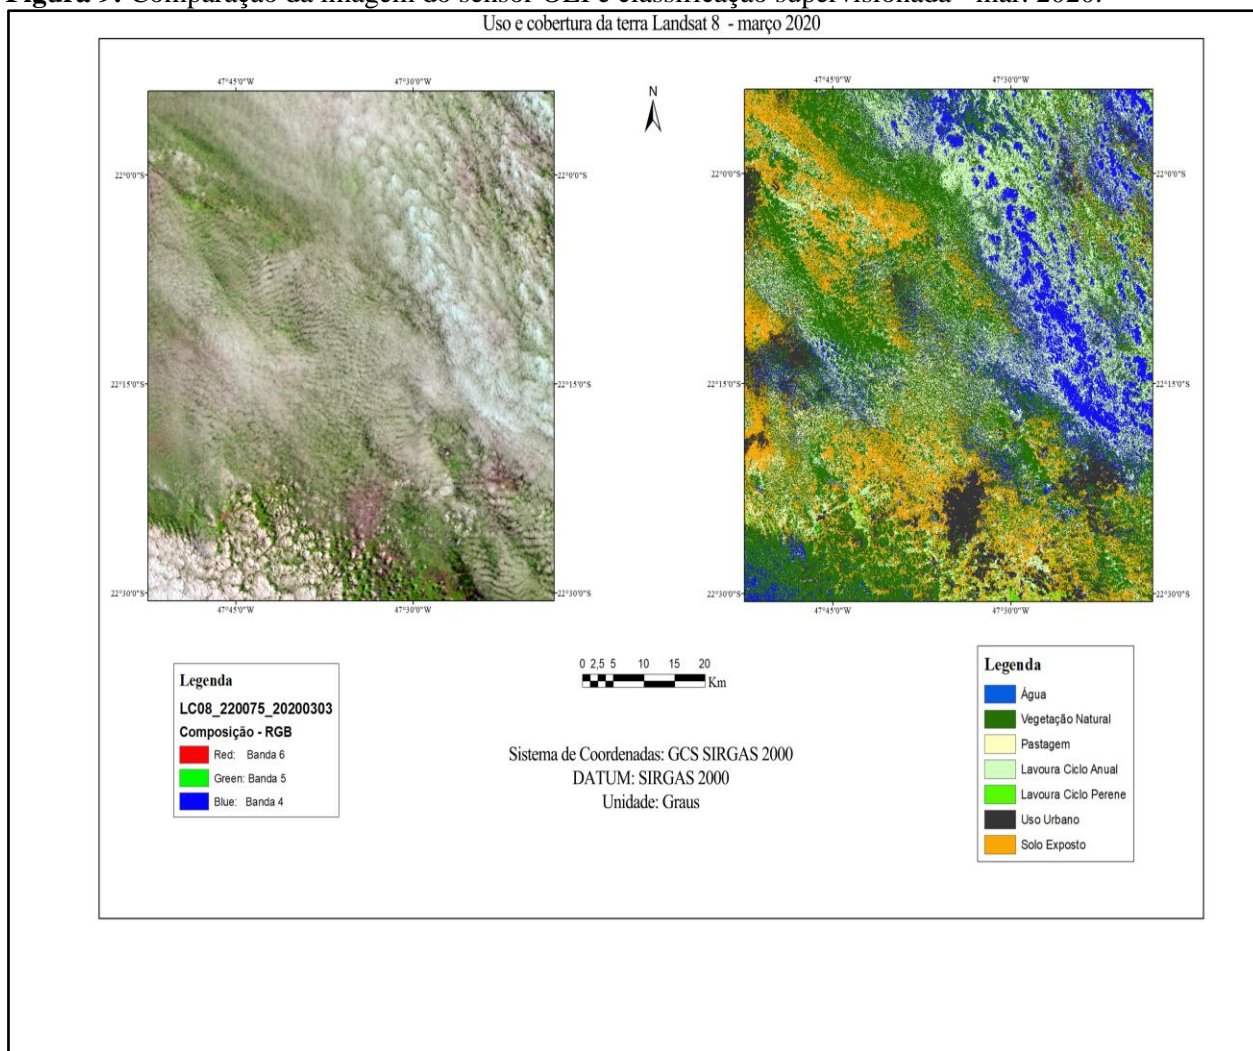


Fonte: Elaborado pelo Autor

6.3 Classificação supervisionada de imagens do sensor OLI – março 2020.

No mês de março o processo de classificação também foi inconsistente em função da excessiva cobertura de nuvens no dia da tomada da imagem em 03 de março de 2020. Apesar dos elevados índices kappa e de acurácia geral (0,96 e 0,97 respectivamente), a classificação não condiz com a realidade de solo, conforme pode ser observado na figura 9.

Figura 9: Comparação da imagem do sensor OLI e classificação supervisionada - mar. 2020.



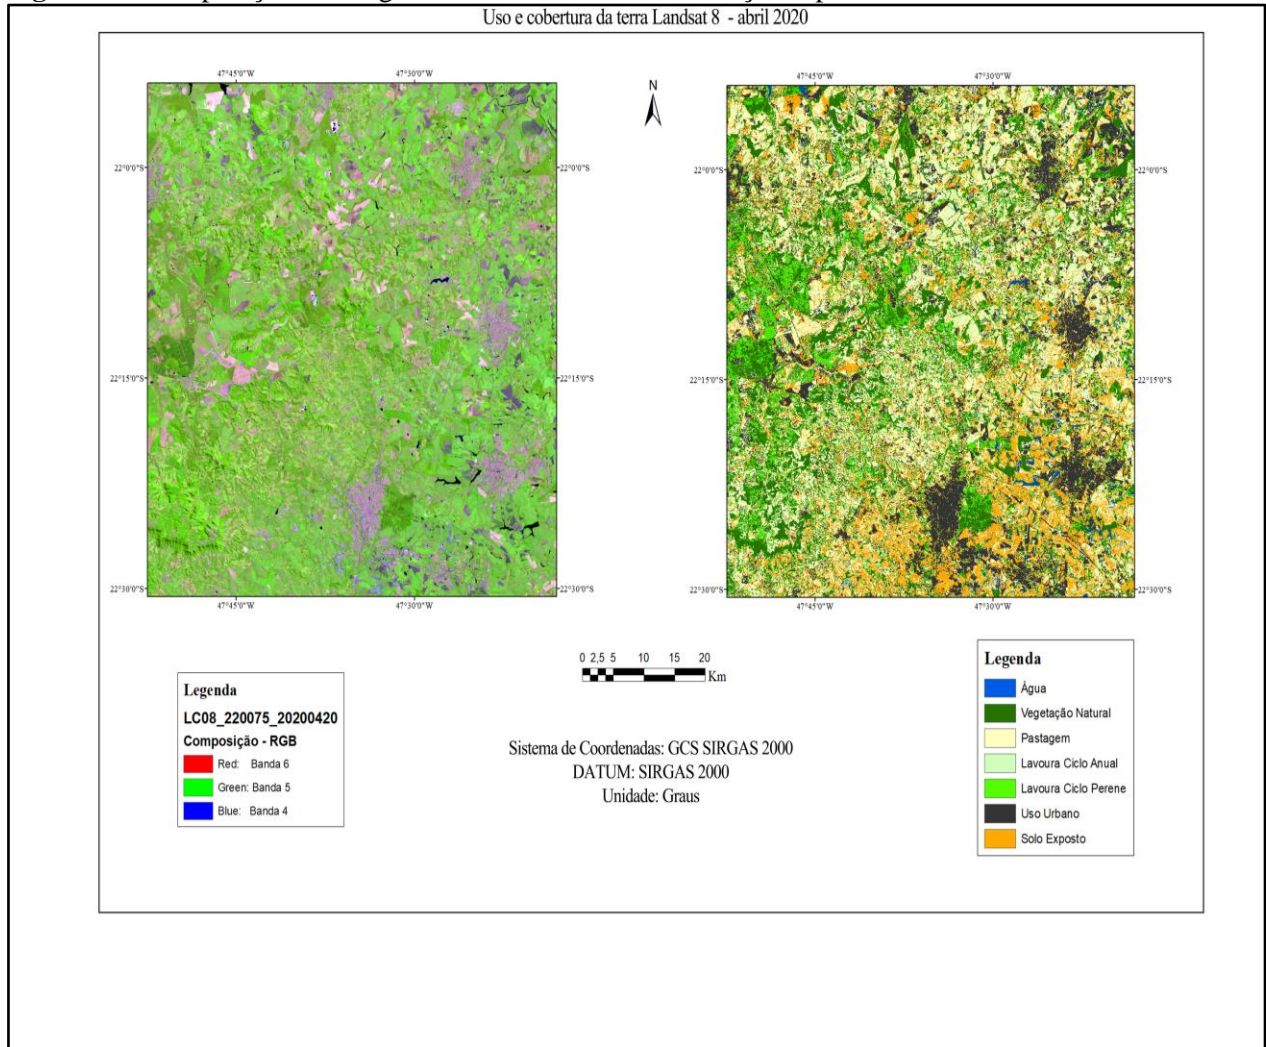
Fonte: Elaborado pelo Autor

6.4 Classificação supervisionada de imagens do sensor OLI – abril 2020.

No mês de abril o processo de classificação apresentou bons resultados, principalmente por a imagem selecionada apresentou uma cobertura de nuvens inferior a 2%. O processo de classificação da imagem do dia 20 de abril de 2020 obteve índice kappa e índice de acurácia geral foram de 0,98. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor foram

elevados, apresentando médias de 0,97. Na classificação do mês de abril é possível notar o predomínio de áreas de pastagens e seu contraste com áreas de cultura anual e perene. As aglomerações e os corpos de água também foram detectados pelo algoritmo random forest. A figura 10 representa o processo de classificação no GEE e a comparação da imagem do sensor OLI.

Figura 10: Comparação da imagem do sensor OLI e classificação supervisionada - abr. 2020.



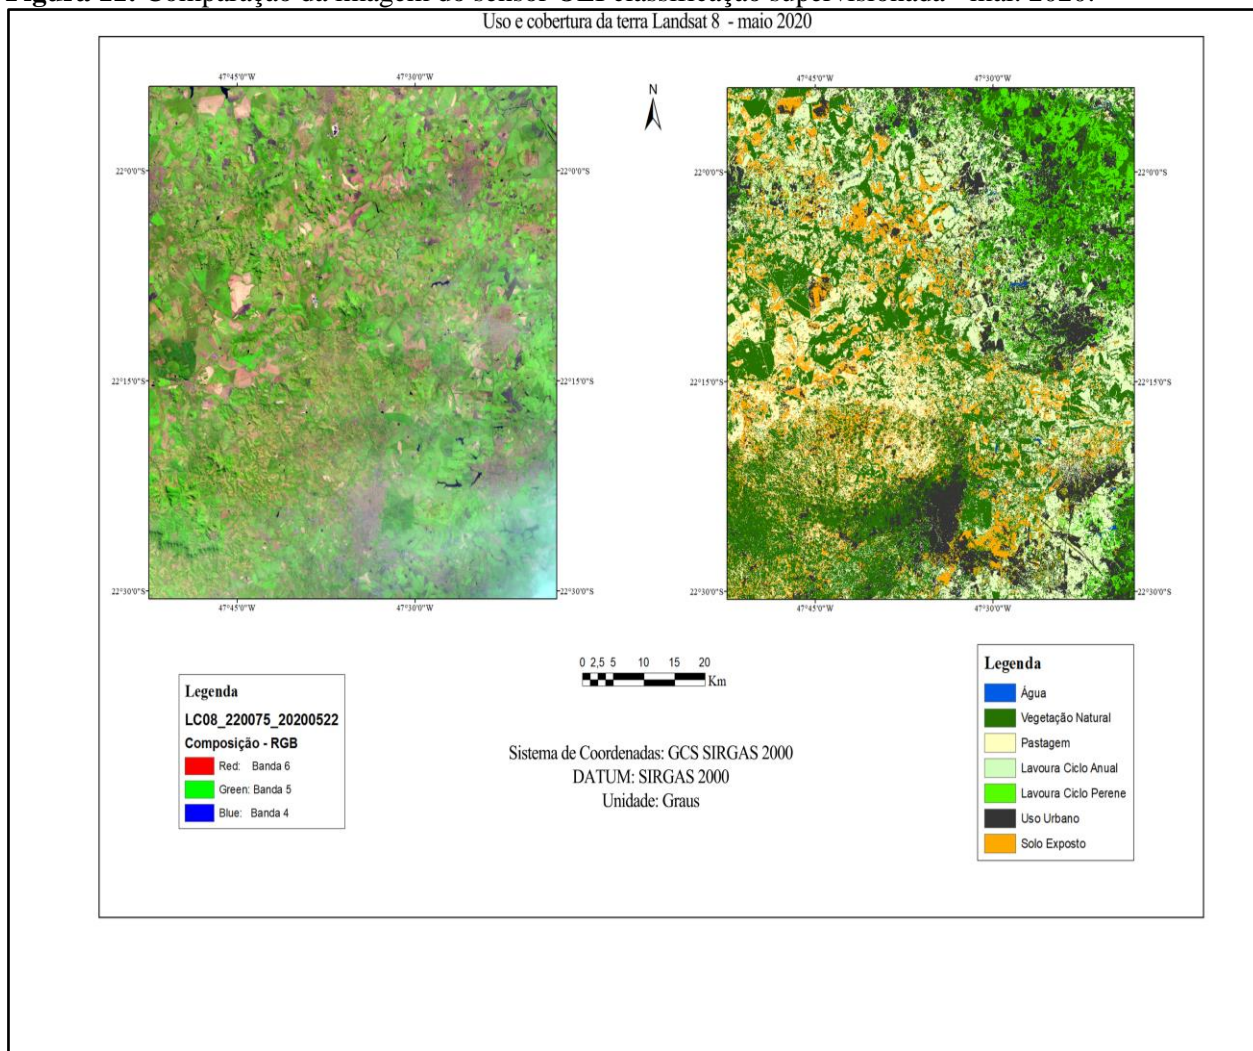
Fonte: Elaborado pelo Autor

6.5 Classificação supervisionada de imagens do sensor OLI – maio 2020.

No mês de maio o processo de classificação apresentou bons resultados somente na metade superior da cena, sendo prejudicado pela presença de nuvens no setor sudeste da área de estudo. No processo de classificação da imagem obtida no dia 22 de maio de 2020, os índices kappa e

índice de acurácia geral de 0,98. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor foram elevados, apresentando médias de 0,96 e 0,97, respectivamente. A figura 11 apresenta os resultados do processo de classificação supervisionada para o mês de maio de 2021.

Figura 11: Comparação da imagem do sensor OLI classificação supervisionada - mai. 2020.




Fonte: Elaborado pelo Autor

6.6 Classificação supervisionada de imagens do sensor OLI – junho 2020.

No mês de junho os resultados foram inconsistentes devido à grande incidência de nuvens na porção norte da área de estudo. O índice kappa foi de 0,93 e a acurácia da validação foi de 0,95. Apesar de serem resultados elevados, eles não condizem a realidade de uso e cobertura da terra. Os resultados do processo de classificação e a comparação entre as imagens do sensor OLI e a

classificação é apresentada na figura 12.

Figura 12: Comparação da imagem do sensor OLI e classificação supervisionada - jun. 2020.

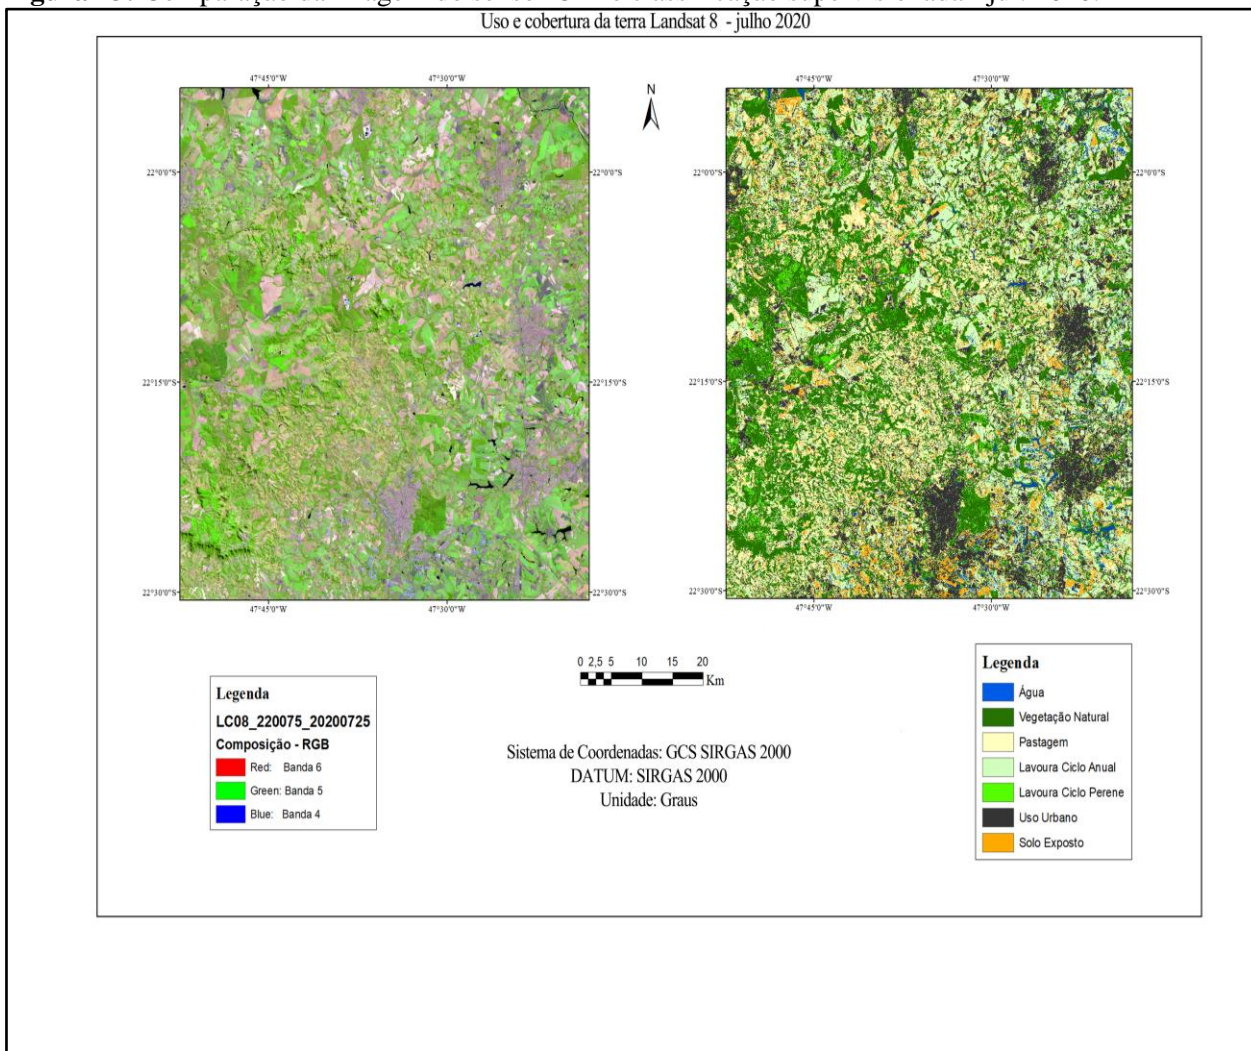


Fonte: Elaborado pelo Autor

6.7 Classificação supervisionada de imagens do sensor OLI – julho 2020.

No mês de julho a classificação não apresentou bons resultados em razão da alta incidência de nuvens em sua porção norte. O índice kappa foi de 0,92 e a acurácia da validação foi de 0,95. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor foram elevados, apresentando médias de 0,95 e 0,96 respectivamente. A figura 13 apresenta os resultados do processo de classificação.

Figura 13: Comparação da imagem do sensor OLI e classificação supervisionada - jul. 2020.



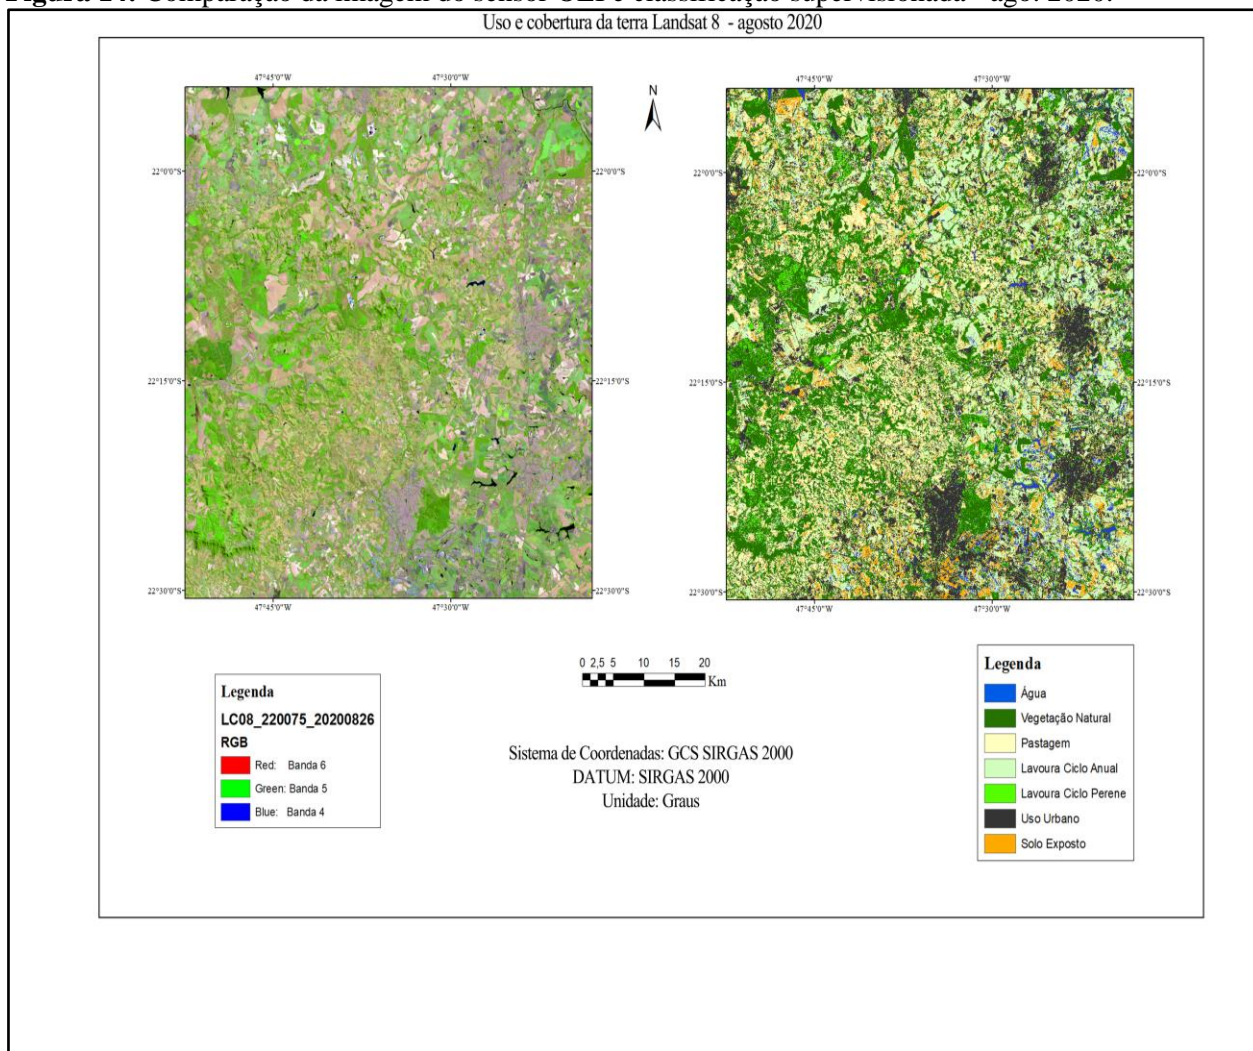
Fonte: Elaborado pelo Autor

6.8 Classificação supervisionada de imagens do sensor OLI – agosto 2020.

No mês de agosto a classificação apresentou bons resultados com índice kappa de 0,96 e acurácia geral de 0,95. No entanto, devido às condições secas do ambiente e da safra da cana, houve muita confusão na distinção entre as classes de solo exposto e áreas urbanas. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor apresentaram médias de 0,95 e 0,96 respectivamente. A figura 14 apresenta os resultados o processo de classificação do uso e cobertura

da terra para o mês de agosto de 2020.

Figura 14: Comparação da imagem do sensor OLI e classificação supervisionada - ago. 2020.



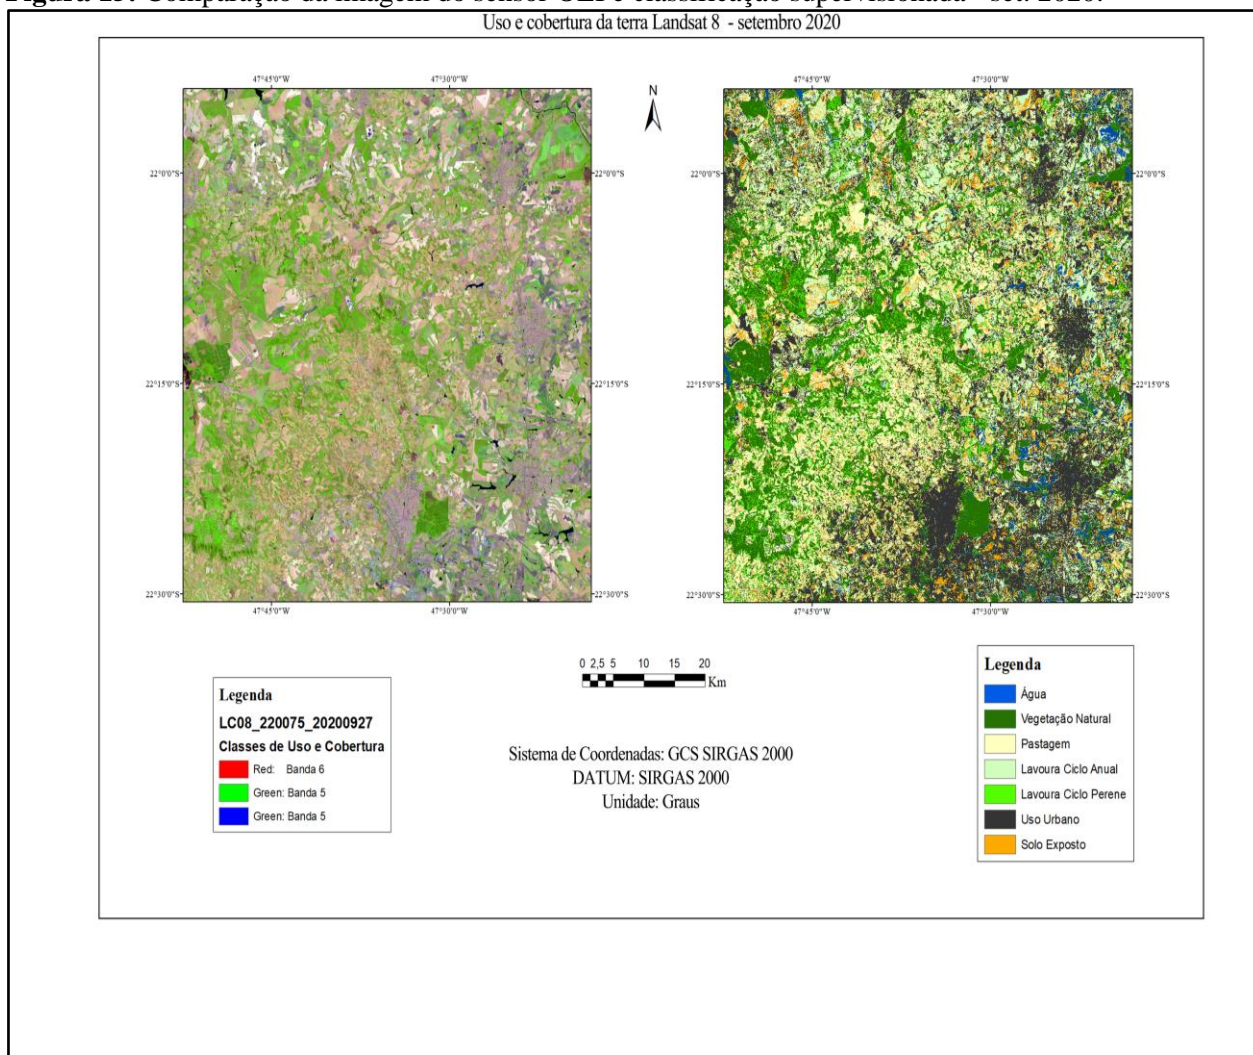
Fonte: Elaborado pelo Autor

6.9 Classificação supervisionada de imagens do sensor OLI – setembro 2020.

No mês de setembro a imagem com poucas nuvens favoreceu o processo de classificação. Nesta cena, assim como na maioria das outras com boas condições atmosféricas, o classificador foi eficaz em separar as classes de vegetação no front e no topo das cuestas arenítico basálticas, situadas na transição entre a Depressão Periférica Paulista e o Planalto Ocidental, sendo possível notar a vegetação natural no front das cuestas, áreas de pastagem, culturas anuais e perenes no topo

e no reverso da cuesta. Nesta cena o classificador encontrou dificuldades em distinguir entre os pixels pertencentes à classe de solo exposto e área urbana. O índice kappa e à acurácia apresentaram resultados de 0,97 e 0,98 respectivamente. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor apresentaram médias de 0,97 e 0,96 respectivamente. A figura 15 apresenta os resultados o processo de classificação do uso e cobertura da terra para o mês de setembro de 2020.

Figura 15: Comparação da imagem do sensor OLI e classificação supervisionada - set. 2020.

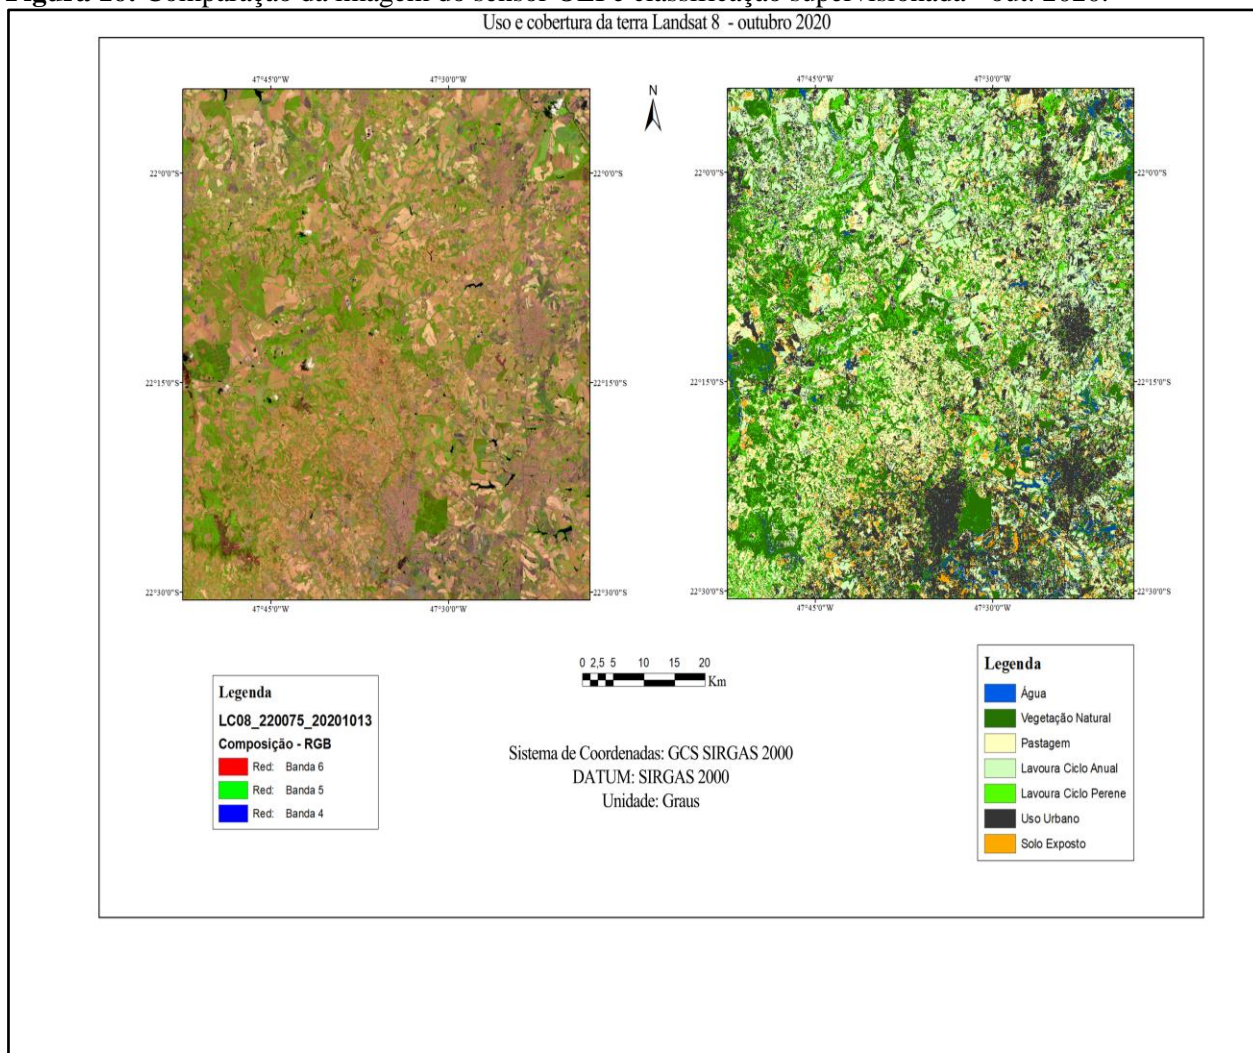


Fonte: Elaborado pelo Autor.

6.10 Classificação supervisionada de imagens do sensor OLI – outubro 2020.

No mês de outubro a imagem apresentou uma cobertura intermediária de nuvens, influenciando negativamente no desempenho do algoritmo de classificação. Os principais problemas observados foram na distinção entre os pixels correspondentes à classe de solo exposto e uso urbano. O setor norte da imagem apresentou uma alta incidência de nuvens. O índice kappa e à acurácia apresentaram resultados de 0,97 e 0,98 respectivamente. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor apresentaram médias de 0,94 e 0,92 respectivamente. A figura 16 apresenta os resultados o processo de classificação do uso e cobertura da terra para o mês de outubro de 2020.

Figura 16: Comparação da imagem do sensor OLI e classificação supervisionada - out. 2020.

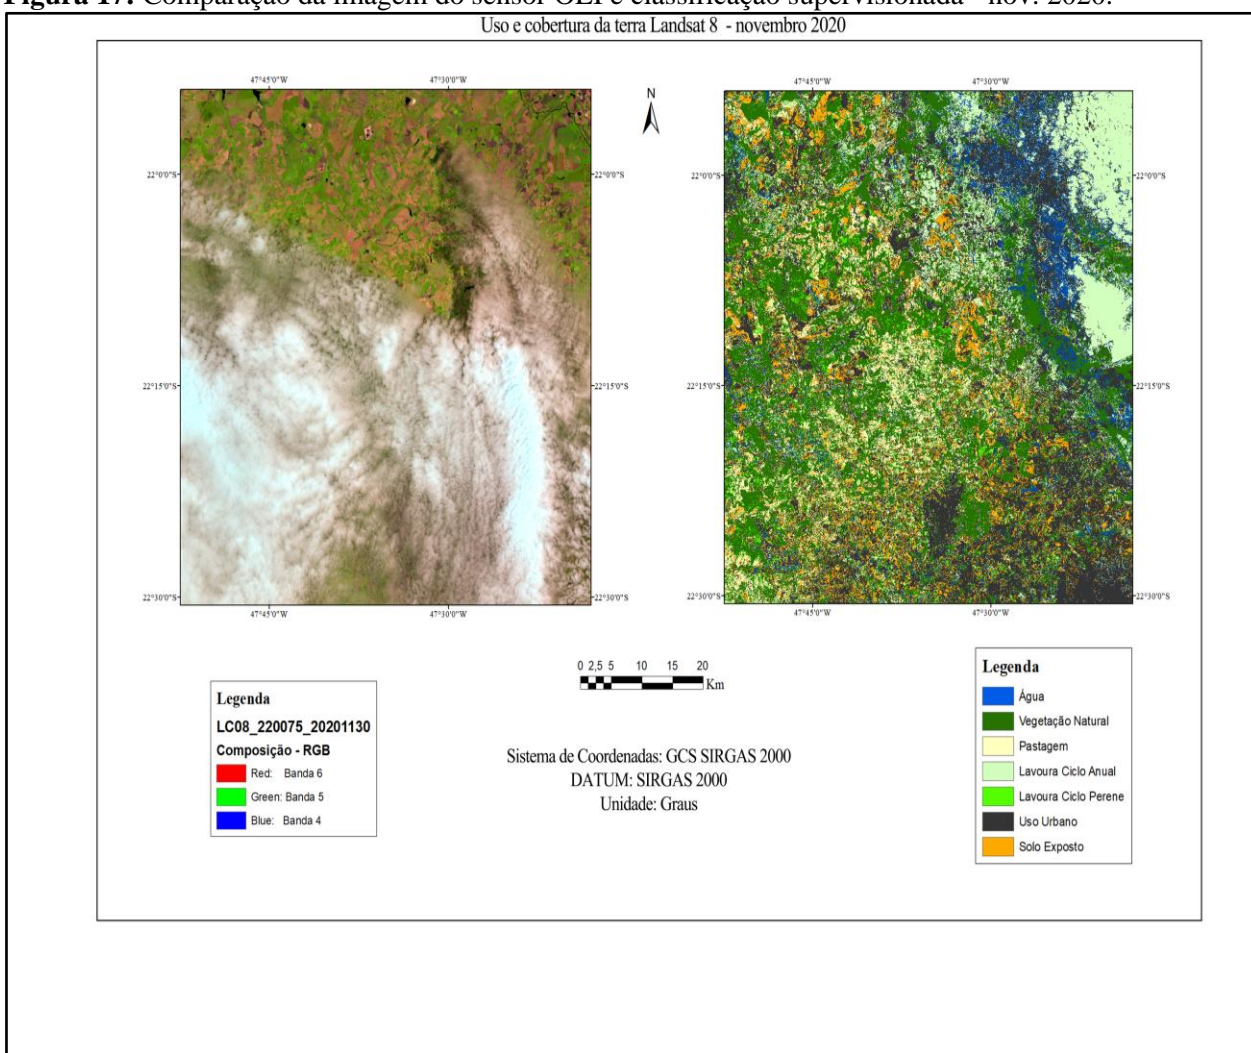


Fonte: Elaborado pelo Autor.

6.11 Classificação supervisionada de imagens do sensor OLI – novembro 2020.

A classificação do mês de novembro não apresentou resultados satisfatórios devido à grande cobertura de nuvens. O índice kappa e a acurácia apresentaram resultados de 0,95 e 0,97 respectivamente. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor apresentaram médias de 0,93 e 0,91 respectivamente. A figura 17 apresenta os resultados o processo de classificação do uso e cobertura da terra para o mês de novembro de 2020.

Figura 17: Comparação da imagem do sensor OLI e classificação supervisionada - nov. 2020.

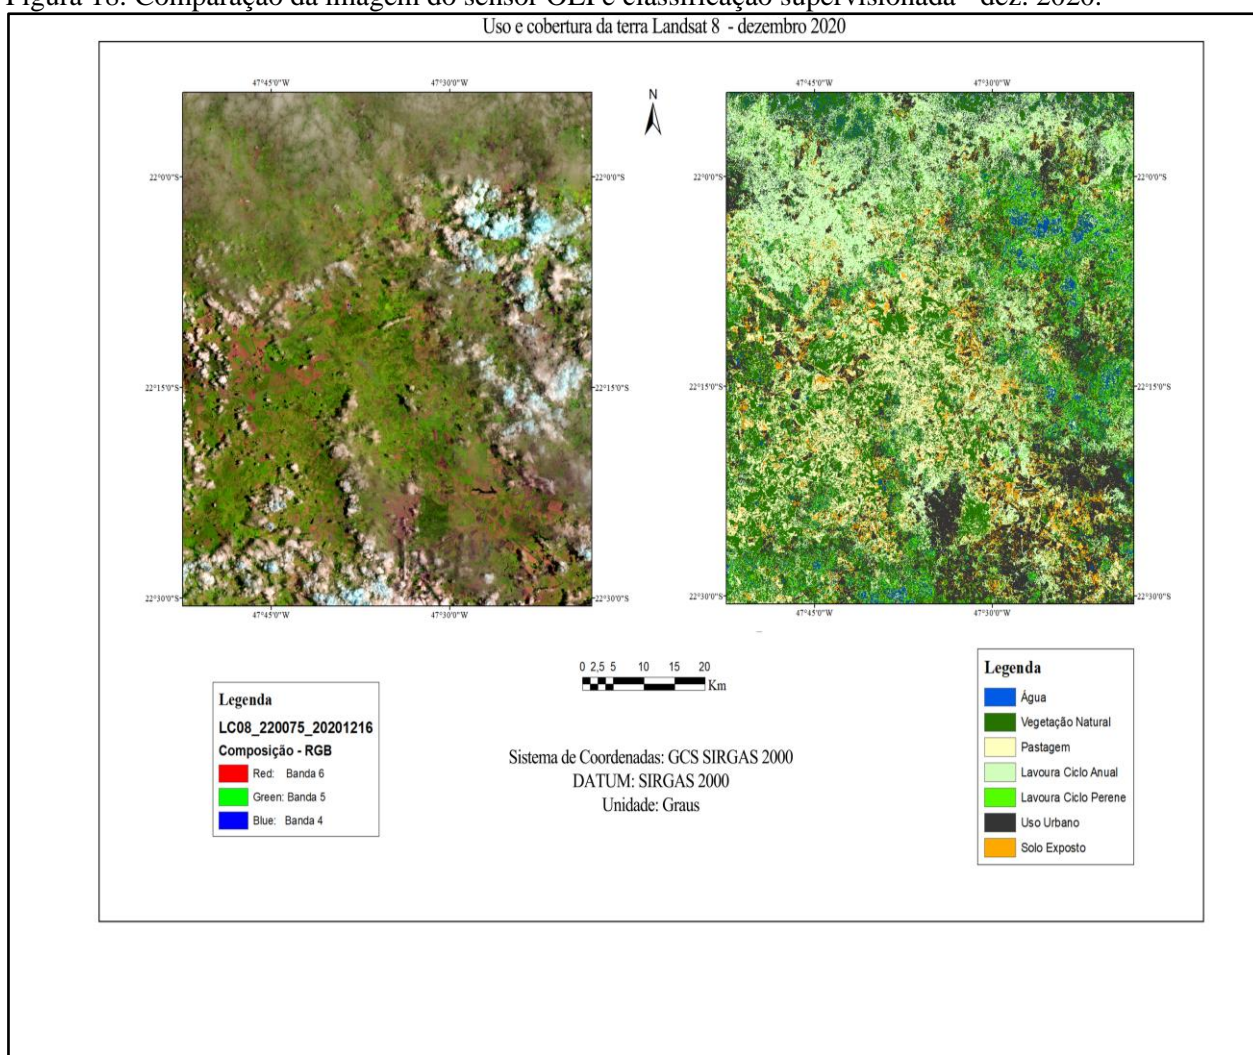


Fonte: Elaborado pelo Autor.

6.12 Classificação supervisionada de imagens do sensor OLI – dezembro 2020.

A classificação do uso e cobertura da terra no mês de dezembro 2020 não apresentou bons resultados em razão da alta incidência de nuvens. O índice kappa e a acurácia apresentaram resultados de 0,93 e 0,95 respectivamente. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor apresentaram médias de 0,93 e 0,91 respectivamente. A figura 18 apresenta os resultados o processo de classificação do uso e cobertura da terra para o mês de dezembro de 2020.

Figura 18: Comparação da imagem do sensor OLI e classificação supervisionada - dez. 2020.



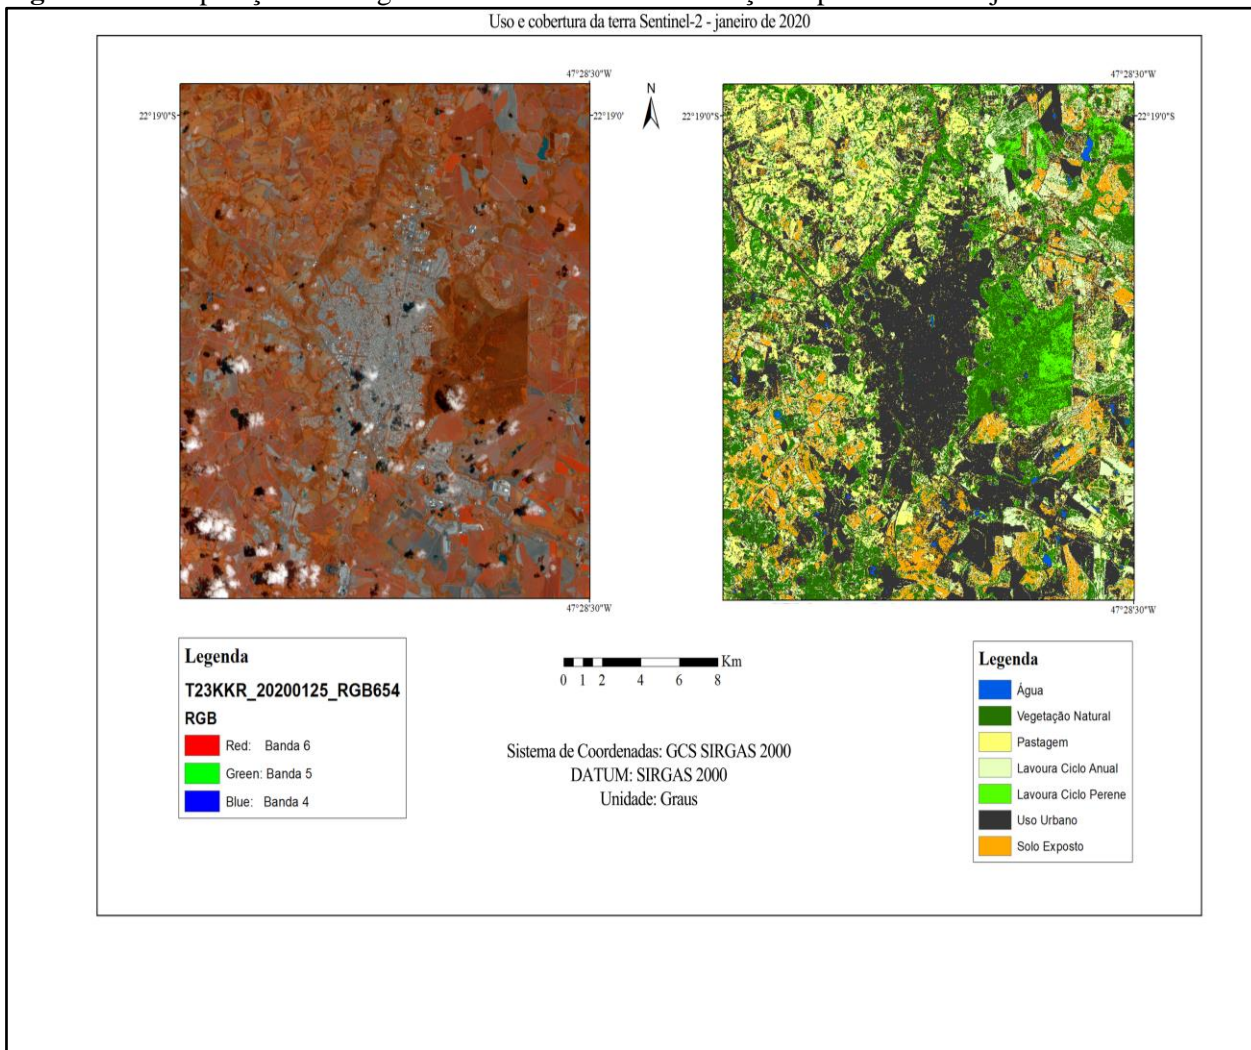
Fonte: Elaborado pelo Autor.

Em se tratando das considerações finais deste trabalho, ressalta-se a precisão dos algoritmos de aprendizado de máquina, como o Random Forest utilizado neste trabalho, possui um alto grau de assertividade em suas predições, fato este que pode ser útil nos diversos contextos que envolvam o uso e cobertura da terra. As aplicabilidades dessas ferramentas abrangem uma série de aspectos do cotidiano que influenciam diretamente no bem estar coletivo e individual, dentre os quais destacam-se a segurança alimentar, as previsões climáticas e o estudo do comportamento dos ecossistemas. O Google Earth Engine demonstrou ser uma ferramenta de grande capacidade e potencial no desenvolvimento de análise espaciais e nas aplicações voltadas ao ensino de Sensoriamento Remoto e Geoprocessamento nos níveis de graduação. O segundo aspecto que ressalta-se neste trabalho foi a ausência de trabalhos de campo para o refinamento do modelo a ponto de fazer a descrição e individualização das culturas agrícolas cultivadas na área de estudo.

6.13 Resultados da classificação de imagens do sensor MSI – janeiro 2020.

A imagem do sensor MSI analisada mês de janeiro, foi coletada no dia 25/01/2021 sendo o processo de classificação favorecido pela baixa concentração de nuvens na atmosfera. O índice kappa foi utilizado para avaliar a concordância entre os pixels classificados e as amostras de referência, utilizadas para calibrar o classificador Random Forest. O índice kappa teve como resultado o valor de 0,97, o que indica um excelente resultado em termos de concordância entre os pixels classificados e as amostras de referência. A acurácia geral da validação, obtida a partir da matriz confusão, foi de 0,95, indicando o somatório de todos os valores que foram classificados corretamente dentro de cada classe de uso e cobertura da terra. O Índice de Acurácia do Consumidor e Índice de Acurácia do Produtor, que têm por objetivo medir quais classes foram melhor discriminadas e quais foram as maiores inconsistências, apresentaram índices elevados, atingindo os índices de 0,97 e 0,96 respectivamente. A figura 19 é um comparativo da composição RGB em falsa cor, elaborada a partir das bandas B6, B5 e B4 e a respectiva imagem após o processo de classificação supervisionada. A principal diferença entre os dados do sensor OLI para os dados do sensor MSI se refere à resolução espacial, sendo de 30 metros no sensor OLI e entre 20 e 10 metros nas bandas do visível e do infravermelho para o sensor MSI, fato que melhora a identificação das feições geométricas da paisagem, bem como a representação gráfica das imagens classificadas.

Figura 19: Comparação da imagem do sensor MSI e classificação supervisionada - jan. 2020.



Fonte: Elaborado pelo Autor.

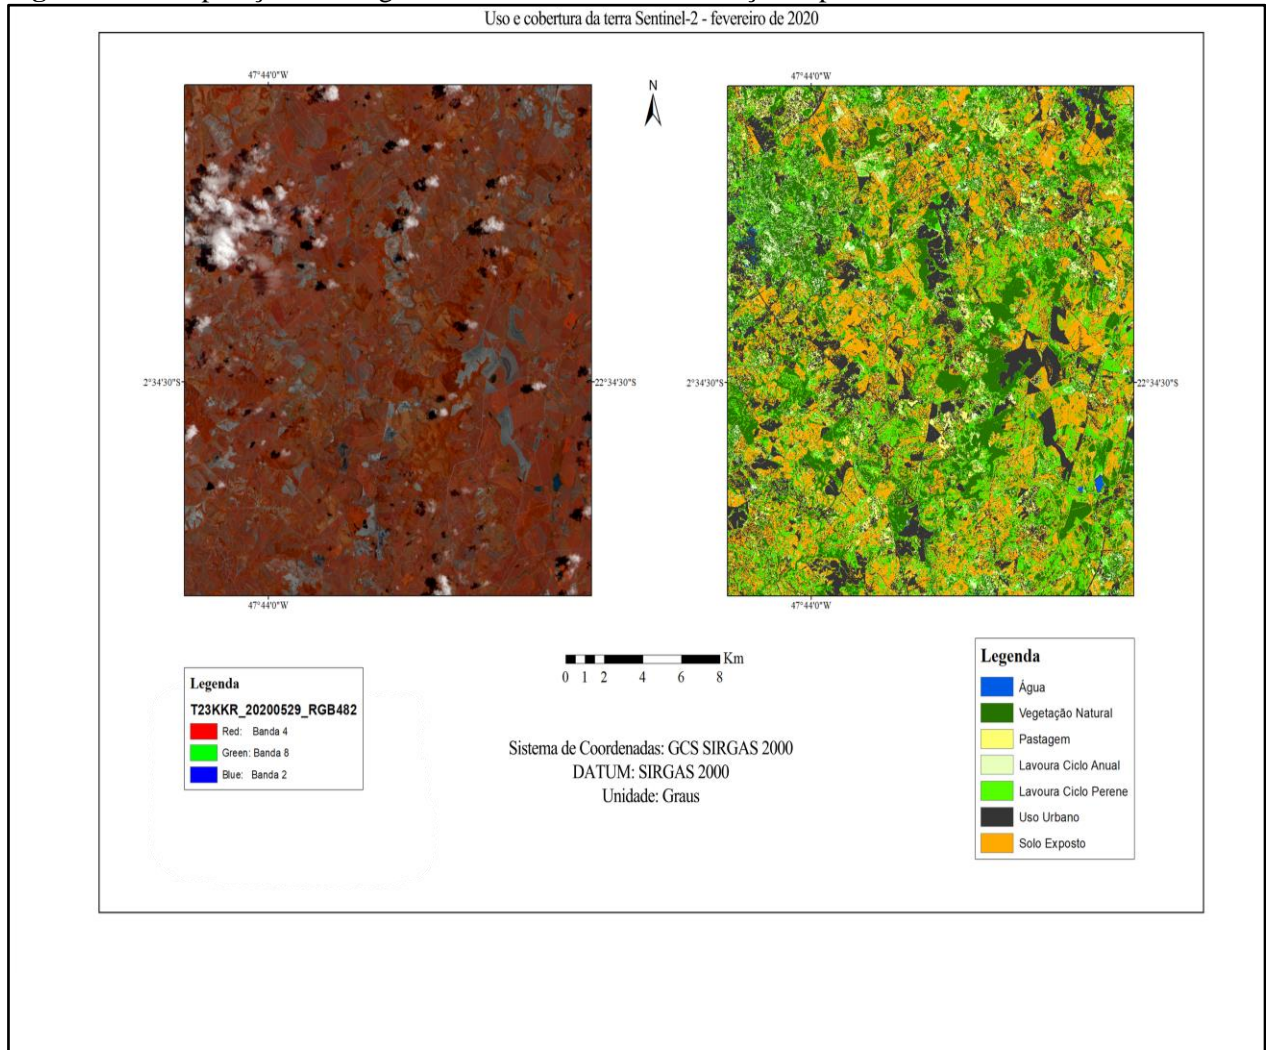
6.14 Resultados da classificação de imagens do sensor MSI – fevereiro 2020.

No mês de fevereiro o foi analisada a área de contato entre vegetação natural, compondo a vegetação ciliar dos rios; áreas de cultivo de culturas de ciclo anual, e a predominância de áreas cobertas por pastos. Na composição RGB utilizando as bandas B8, B3 e B2 as áreas em tons de cinza são áreas de solo exposto, os tons em vermelho escuro e textura grosseira são áreas de vegetação natural e culturas perenes. As áreas em tons de vermelho claro disposto de forma irregular representam as áreas de pastagem e os tons de vermelho intermediário de textura homogênea representam áreas de cultivos anuais.

O processo de classificação apresentou bons resultados, sendo possível distinguir as áreas de pastagem e as culturas de ciclo anual, presentes no centro da cena. O índice kappa foi de 0,96

e o índice de acurácia geral foram de 0,86, o que indica que o classificador foi eficiente para distinguir entre as classes de uso e cobertura da terra analisadas. O Índice de Acurácia do Consumidor e o Índice de Acurácia do Produtor foram elevados, apresentando médias de 0,88 e 0,9. A figura 20 apresenta os resultados do processo de classificação do uso da terra para o mês de fevereiro.

Figura 20: Comparação da imagem do sensor MSI e classificação supervisionada - fev. 2020.



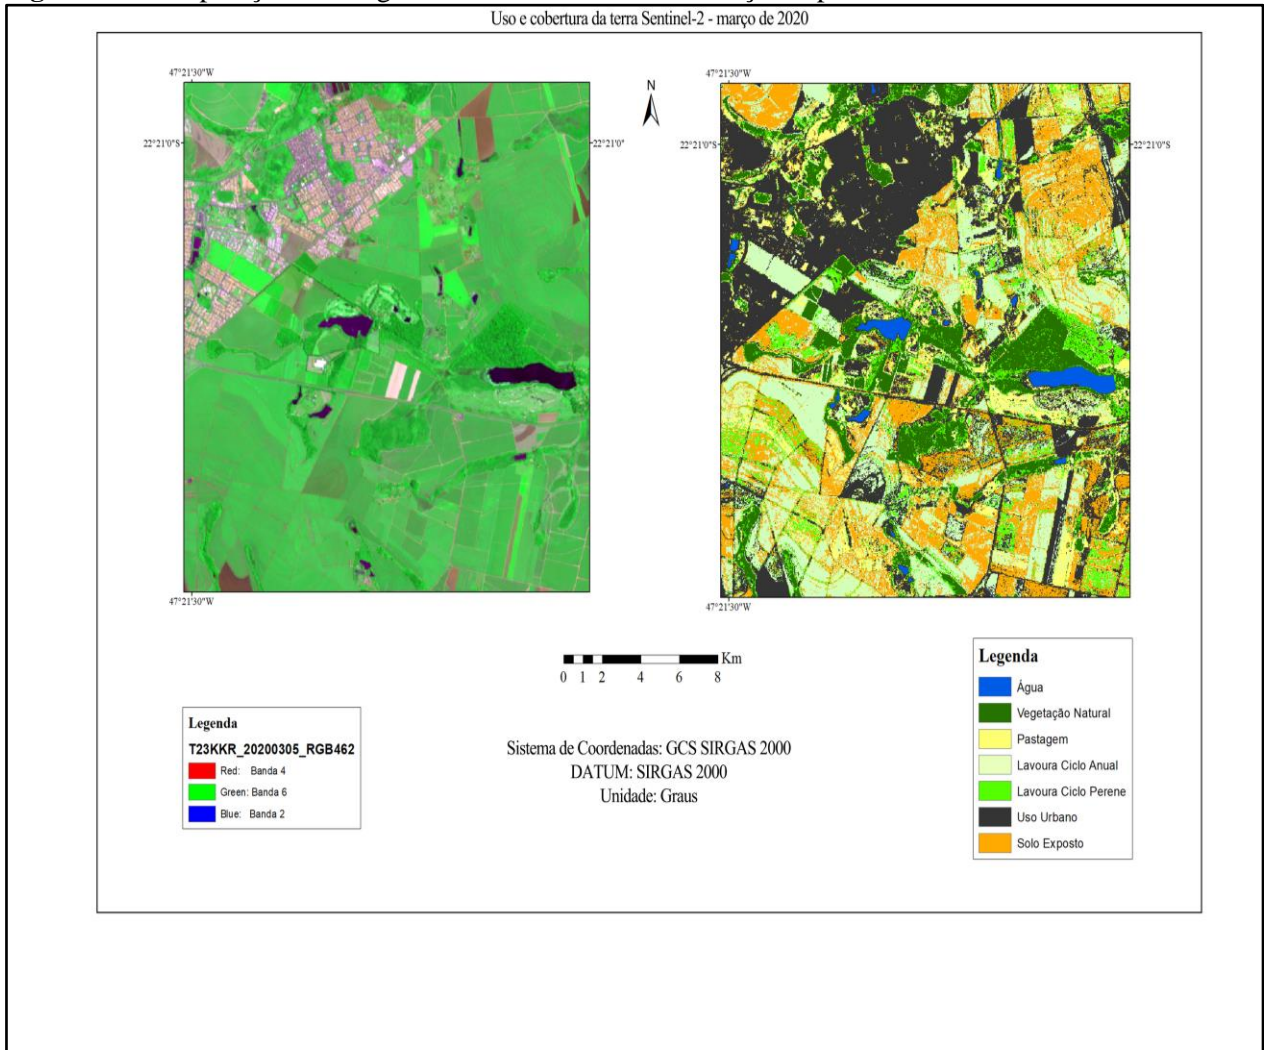
Fonte: Elaborado pelo Autor.

6.15 Resultados da classificação de imagens do sensor MSI – março 2020.

O processo de classificação do uso da terra pra o mês de março foi favorecido pela baixa presença de nuvens. A partir da composição RGB falsa cor utilizando as bandas B4, B8 e B2 foi eficiente para identificar de forma eficiente todas as 7 classes de uso e cobertura da terra analisados nesta pesquisa. O Destaque da classificação foi a satisfatória diferenciação entre solo exposto e

áreas urbanas, bem como entre vegetação natural e os cultivos de ciclo anual. Vale também destacar a eficiência do algoritmo em classificar as vias de circulação, visíveis no centro de ambas as imagens da figura 21. O índice kappa foi de 0,95 e a acurácia geral do mapeamento obteve valor de 0,88. Os índices de acurácia do consumidor e acurácia do produtor foram de 0,9 e 0,88 respectivamente.

Figura 21: Comparação da imagem do sensor MSI e classificação supervisionada - mar. 2020.



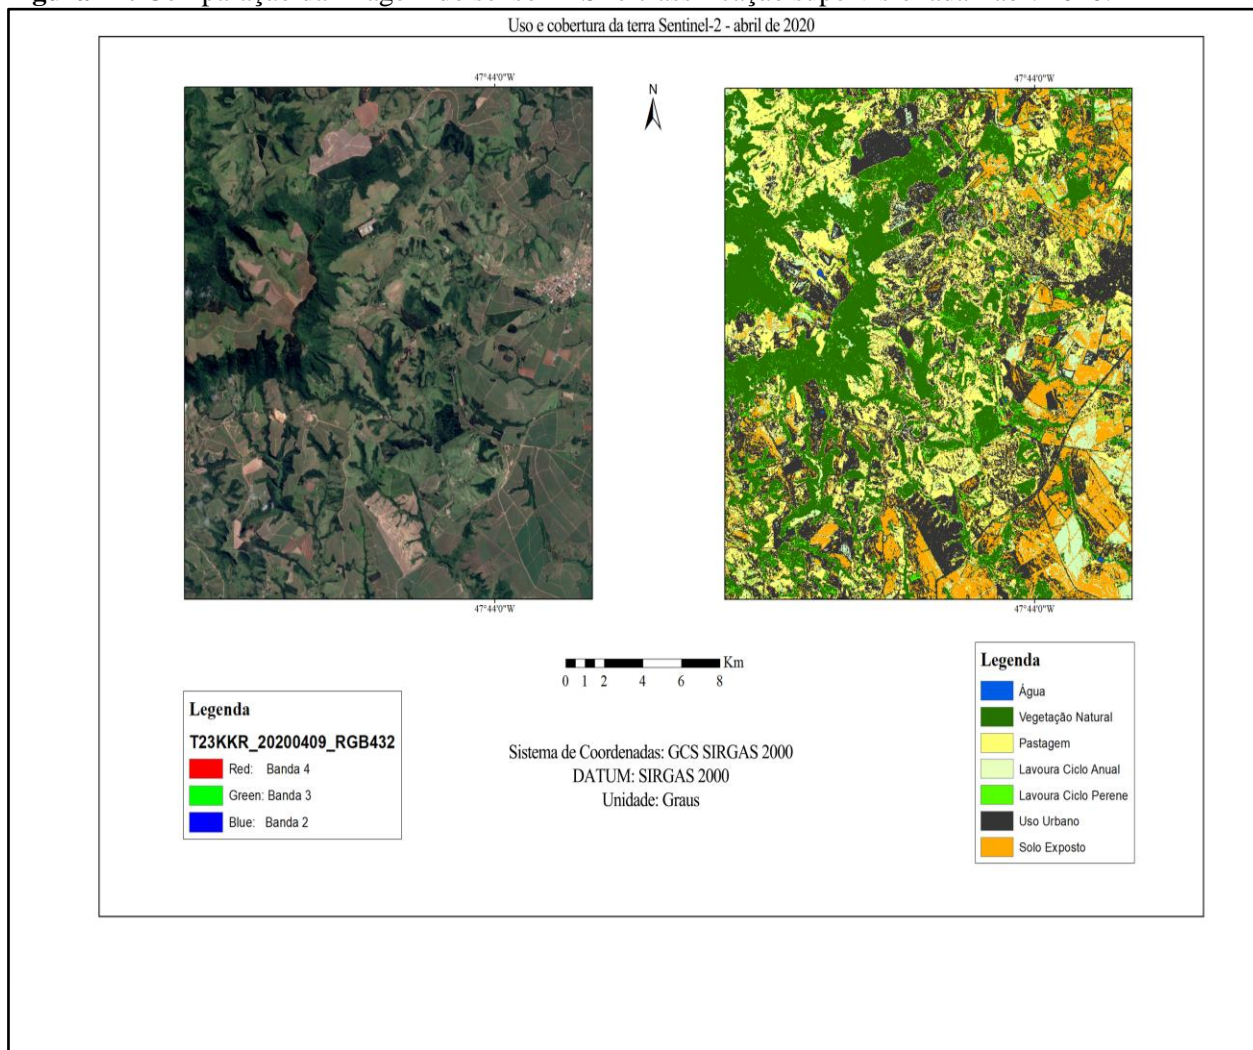
Fonte: Elaborado pelo Autor.

6.16 Resultados da classificação de imagens do sensor MSI – abril 2020.

No mês de abril o processo de classificação apresentou bons resultados, principalmente por ter sido classificada uma imagem com uma cobertura de nuvens inferior a 2%. A partir da composição RGB em cor natural, feita a partir das bandas B4, B3 e B2, destaca-se a área de transição de relevo entre a Depressão Periférica Paulista e o Planalto Oriental. Na zona de contato

entre essas províncias, destaca-se o relevo cuestiforme, composto pela Cuestas areníticas/basálticas. O processo de classificação foi eficiente para identificar as áreas de vegetação natural no front ou esparpas das cuestas, e também a vegetação ciliar presente no entorno dos curdos de água que descem o front das cuestas. O aspecto negativo do processo de classificação da imagem do mês de abril foi a confusão do algoritmo em distinguir entre as classes de uso urbano e solo exposto, como pode ser observado no topo das cuestas. O índice kappa obteve valor de 0,9 e a acurácia geral do mapeamento foi de 0,8. Os índices de acurácia do consumidor e do produtor foram de 0,79 e 0,81 respectivamente. A figura 22 apresenta a composição RGB em cor natural, e a imagem rotulada com as classes de uso e cobertura da terra, resultantes do processo de classificação supervisionada.

Figura 22: Comparação da imagem do sensor MSI e classificação supervisionada - abr. 2020.

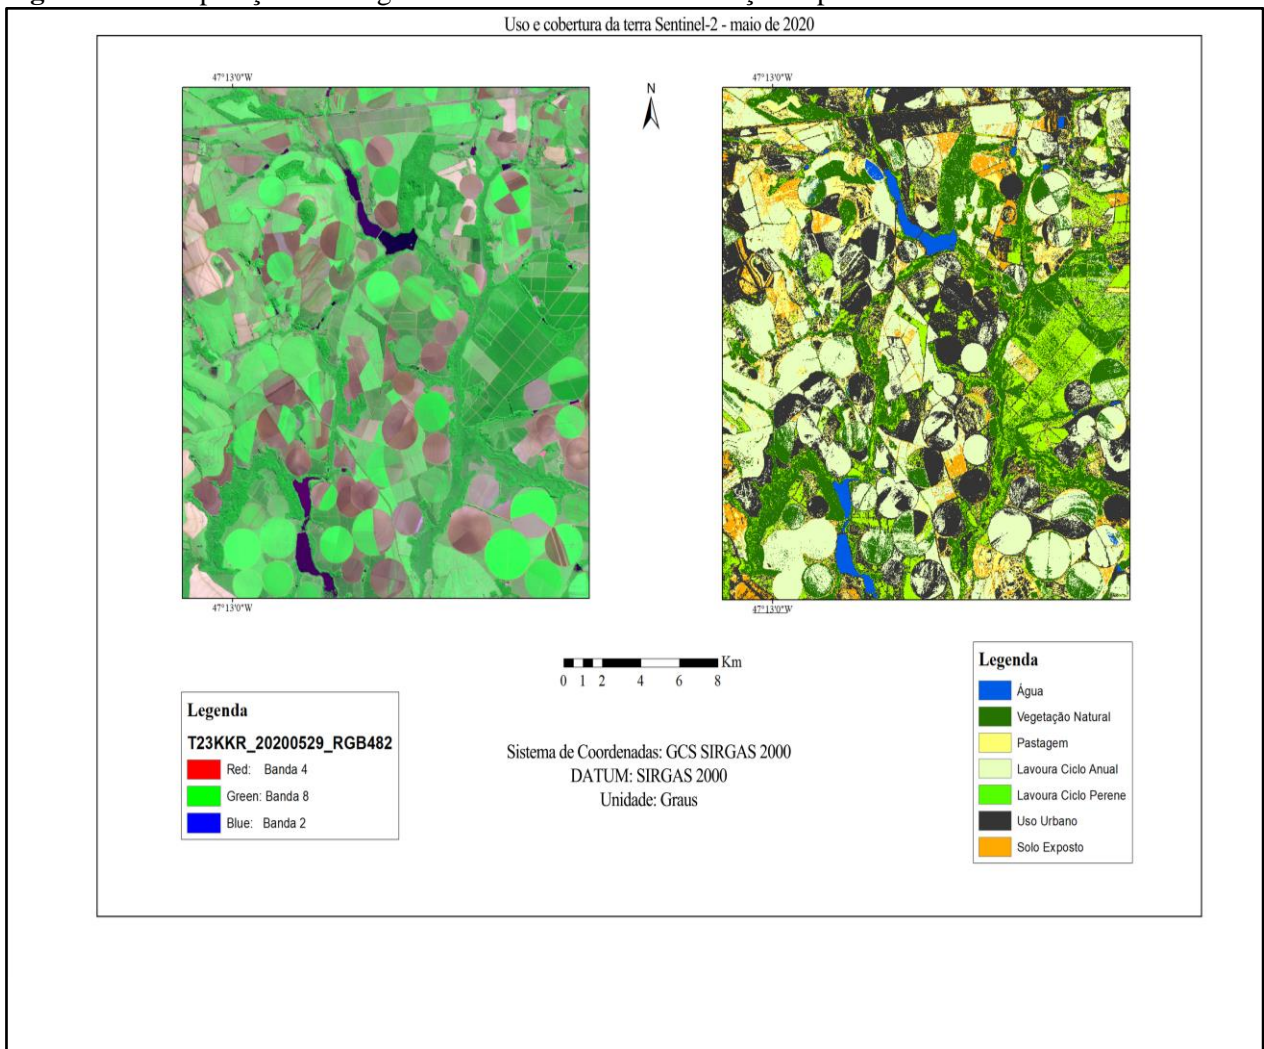


Fonte: Elaborado pelo Autor.

6.17 Resultados da classificação de imagens do sensor MSI – maio 2020.

Na imagem do mês de maio, classificada a partir da composição RGB em falsa cor com as bandas B4, B8 e B2, destaca-se as formas geométricas bem como a simetria dos campos de cultivo com pivôs centrais de irrigação. Nessas áreas é possível observar solo exposto e diversos tons de verde e texturas variáveis representando diferentes estágios de crescimento dos cultivos agrícolas. O desataque negativo, semelhantemente ao ocorrido na classificação da imagem do mês de abril, observa-se áreas que o algoritmo classificou o solo exposto, presentes em alguns pivôs centrais, como sendo áreas urbanas. O processo de classificação da imagem de maio de 2020 obteve índice kappa de 0,92 e acurácia geral do mapeamento de 0,84. A acurácia do consumidor obteve valor de 0,88 e a acurácia do produtor obteve resultado de 0,86. A figura 23 apresenta os resultados da classificação do uso da terra para o mês de maio.

Figura 23: Comparação da imagem do sensor MSI e classificação supervisionada - mai. 2020.

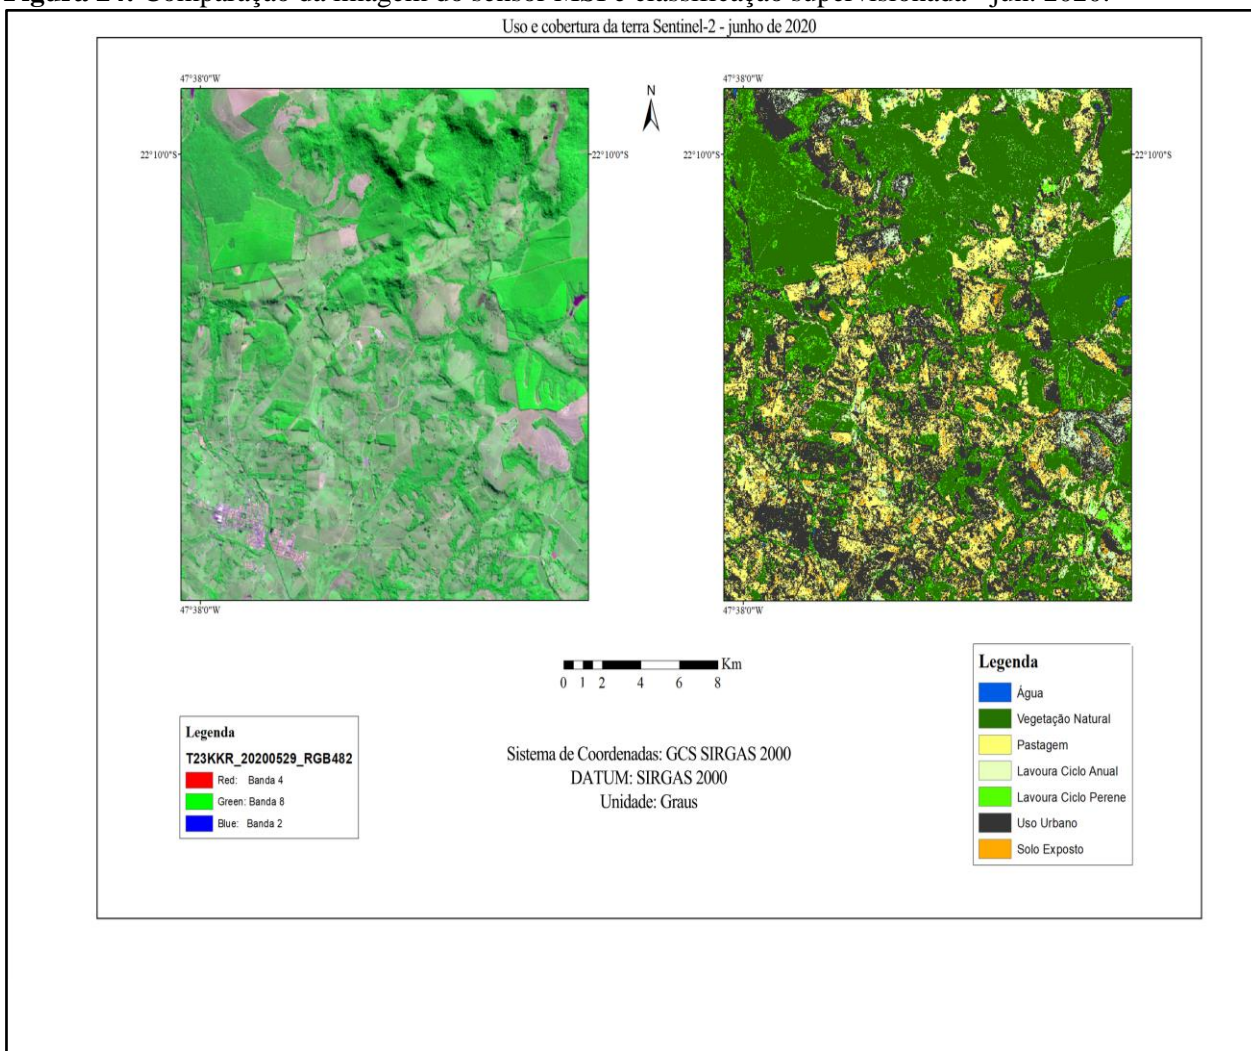


Fonte: Elaborado pelo Autor.

6.18 Resultados da classificação de imagens do sensor MSI – junho 2020.

A imagem do mês de junho foi classificada a partir da composição RGB em falsa cor, produzida a partir das bandas B4, B8 e B2. Nas imagens presentes na figura 24 destaca-se a rugosidade do relevo e as áreas de vegetação densa, presentes nas áreas de relevo escarpado e nas áreas de silvicultura. Na faixa central da imagem destaca-se a presença de colinas cobertas por pastos e cortadas por cursos d'água com vegetação natural em seu entorno. O algoritmo de classificação foi eficiente para distinguir as classes de uso e cobertura da terra destacadas, obtendo índice kappa de 0,95 e acurácia geral de 0,82. Os índices de acurácia do consumidor e acurácia do produtor foram de 0,86 e 0,85 respectivamente.

Figura 24: Comparação da imagem do sensor MSI e classificação supervisionada - jun. 2020.



Fonte: Elaborado pelo Autor.

6.19 Resultados da classificação de imagens do sensor MSI – julho 2020.

A imagem do mês de julho corresponde a região do médio curso do rio Mogi Guaçu, sendo analisada a partir da composição RGB em falsa cor com as bandas B4, B8 e B2. Na margem direita do rio destacam-se as áreas de silvicultura que foram corretamente classificadas, sendo possível observar a geometria dos talhões cortados pelas estadas rurais. Na margem esquerda do rio Mogi observam-se áreas de solo exposto que foram erroneamente classificadas como áreas urbanas. O processo de classificação da imagem de julho de 2020 obteve índice kappa de 0,92 e acurácia geral do mapeamento de 0,87. A acurácia do consumidor obteve valor de 0,88 e a acurácia do produtor obteve resultado de 0,86. A figura 23 apresenta os resultados da classificação do uso da terra para o mês de julho.

Figura 25: Comparação da imagem do sensor MSI e classificação supervisionada - jul. 2020.

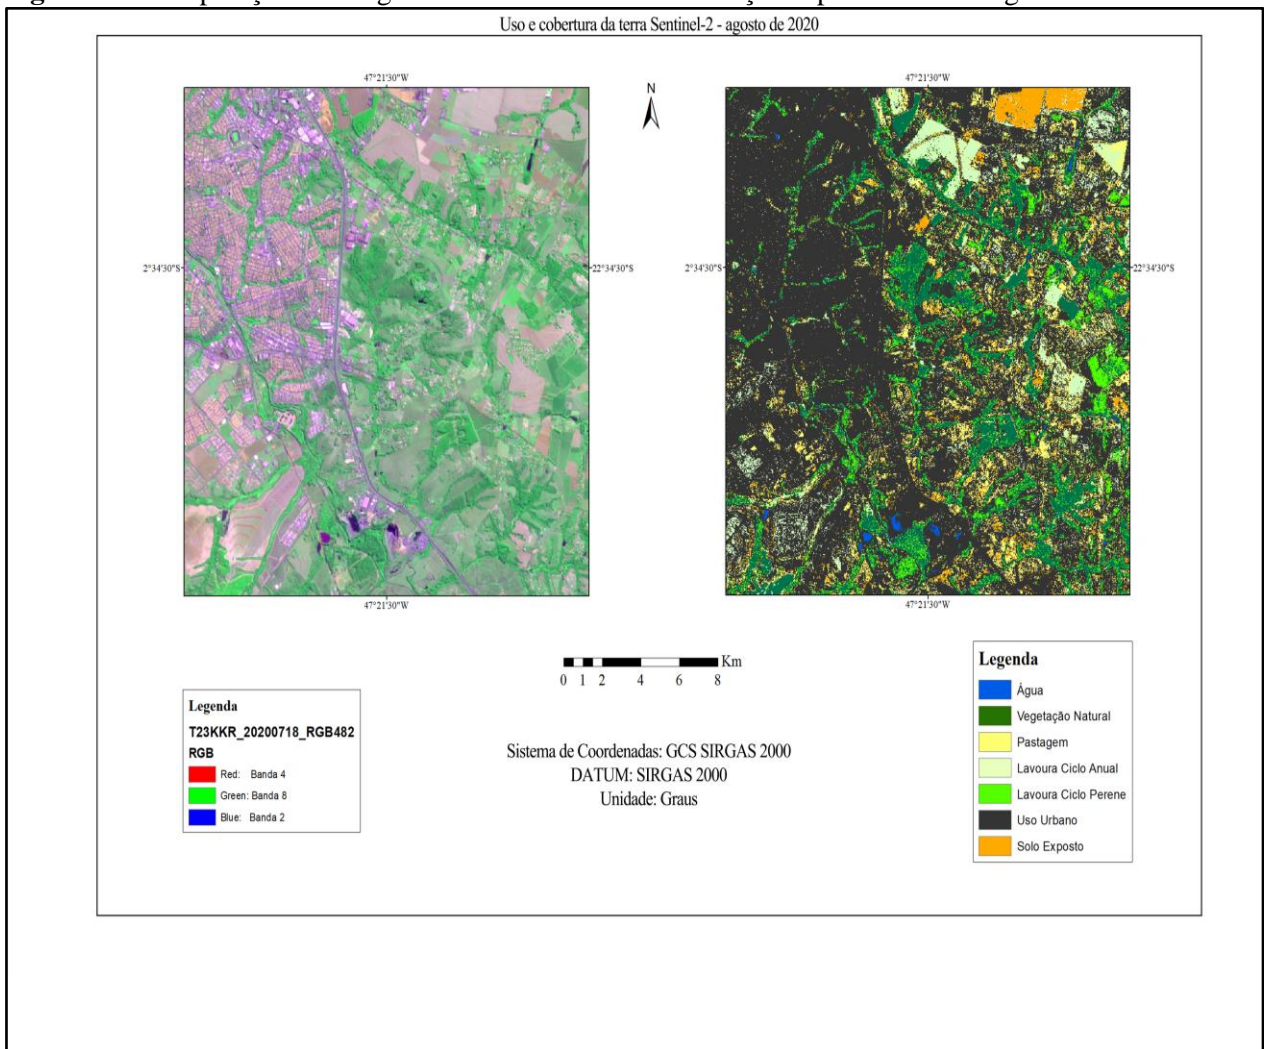


Fonte: Elaborado pelo Autor.

6.20 Resultados da classificação de imagens do sensor MSI – agosto 2020.

A imagem do mês de agosto foi analisada a partir da composição RGB em falsa cor com as bandas B4, B8 e B2. A área estudada destaca-se o contato entre a área urbana do município de Limeira e a vegetação no entorno dos canais de drenagem que passam pela área urbana. A vegetação natural foi corretamente classificada em tons de verde escuro, e a área urbana em tons de cinza escuro. Destaca-se também as cavas de mineração preenchidas com água, presentes no quadrante sul da imagem. Observa-se também que o algoritmo não foi eficiente em classificar as áreas de solo exposto. O índice kappa do processo de classificação foi de 0,95 e acurácia geral do mapeamento de 0,85. A acurácia do consumidor obteve valor de 0,88 e a acurácia do produtor obteve resultado de 0,86. A figura 26 apresenta os resultados da classificação do uso da terra para o mês de agosto.

Figura 26: Comparação da imagem do sensor MSI e classificação supervisionada - ago. 2020.

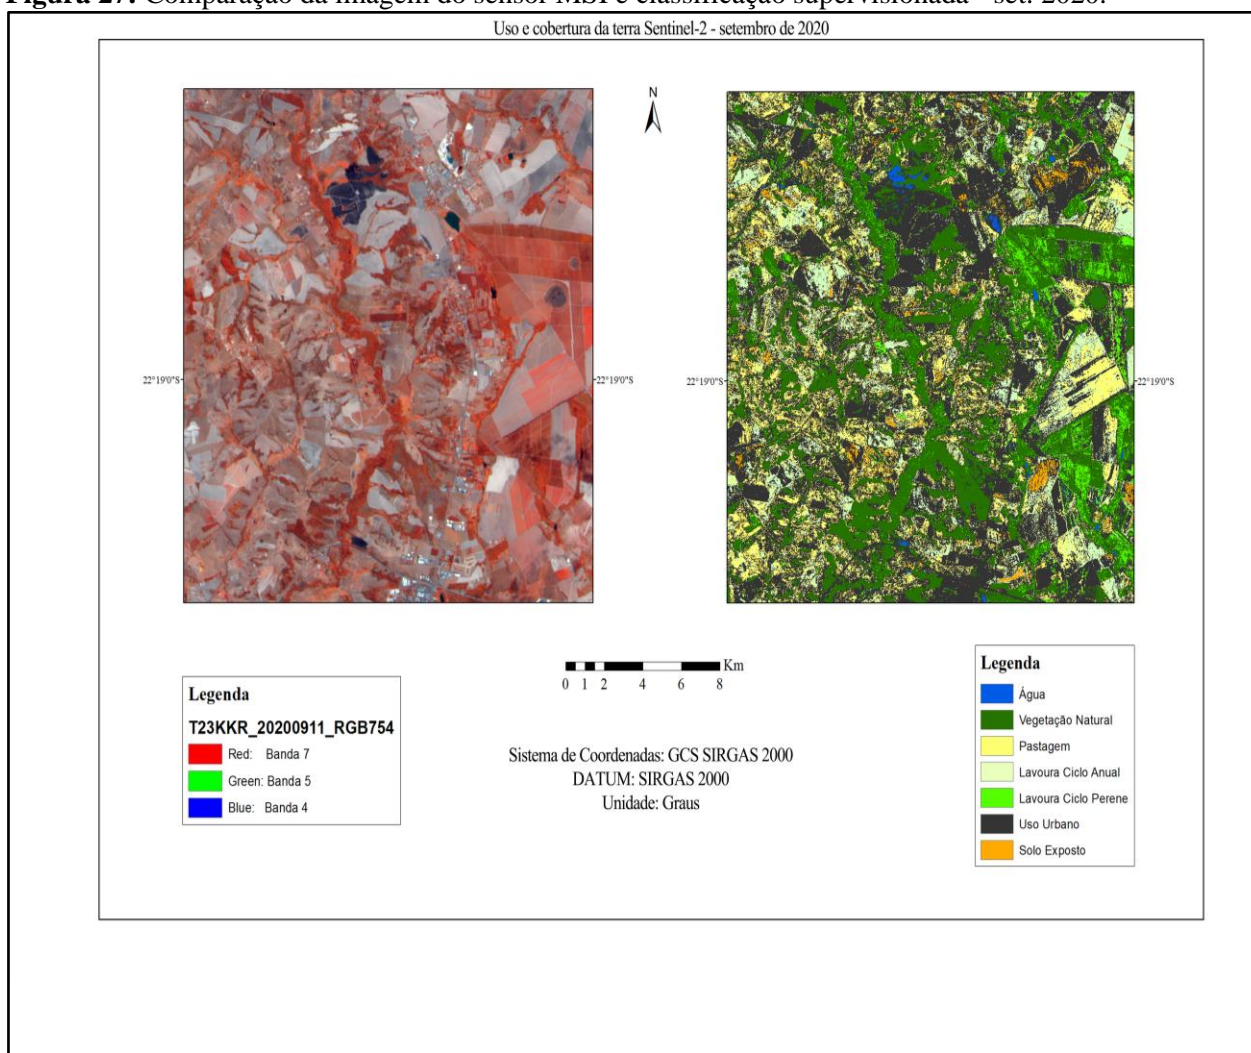


Fonte: Elaborado pelo Autor.

6.21 Resultados da classificação de imagens do sensor MSI –setembro 2020.

No mês de setembro a classificação foi realizada a partir da composição RGB em falsa cor com as bandas B7, B4 e B2, sendo possível situar no centro da imagem regiões que sofreram com processos de incêndios recentes. O algoritmo foi ineficiente em classificar essas áreas, sendo atribuída a classe temática uso urbano ao invés de solo exposto. No centro da imagem observa-se a vegetação ciliar na região do médio curso do rio Corumbataí e no setor leste extensas áreas de cultivo de cana de açúcar que foram classificadas como pasto, vegetação natural, cultivos perenes e anuais. O índice kappa foi de 0,91 e acurácia geral do mapeamento de 0,82. As acurácias do consumidor e do produtor foram de 0,77 e 0,78 respectivamente.

Figura 27: Comparação da imagem do sensor MSI e classificação supervisionada - set. 2020.

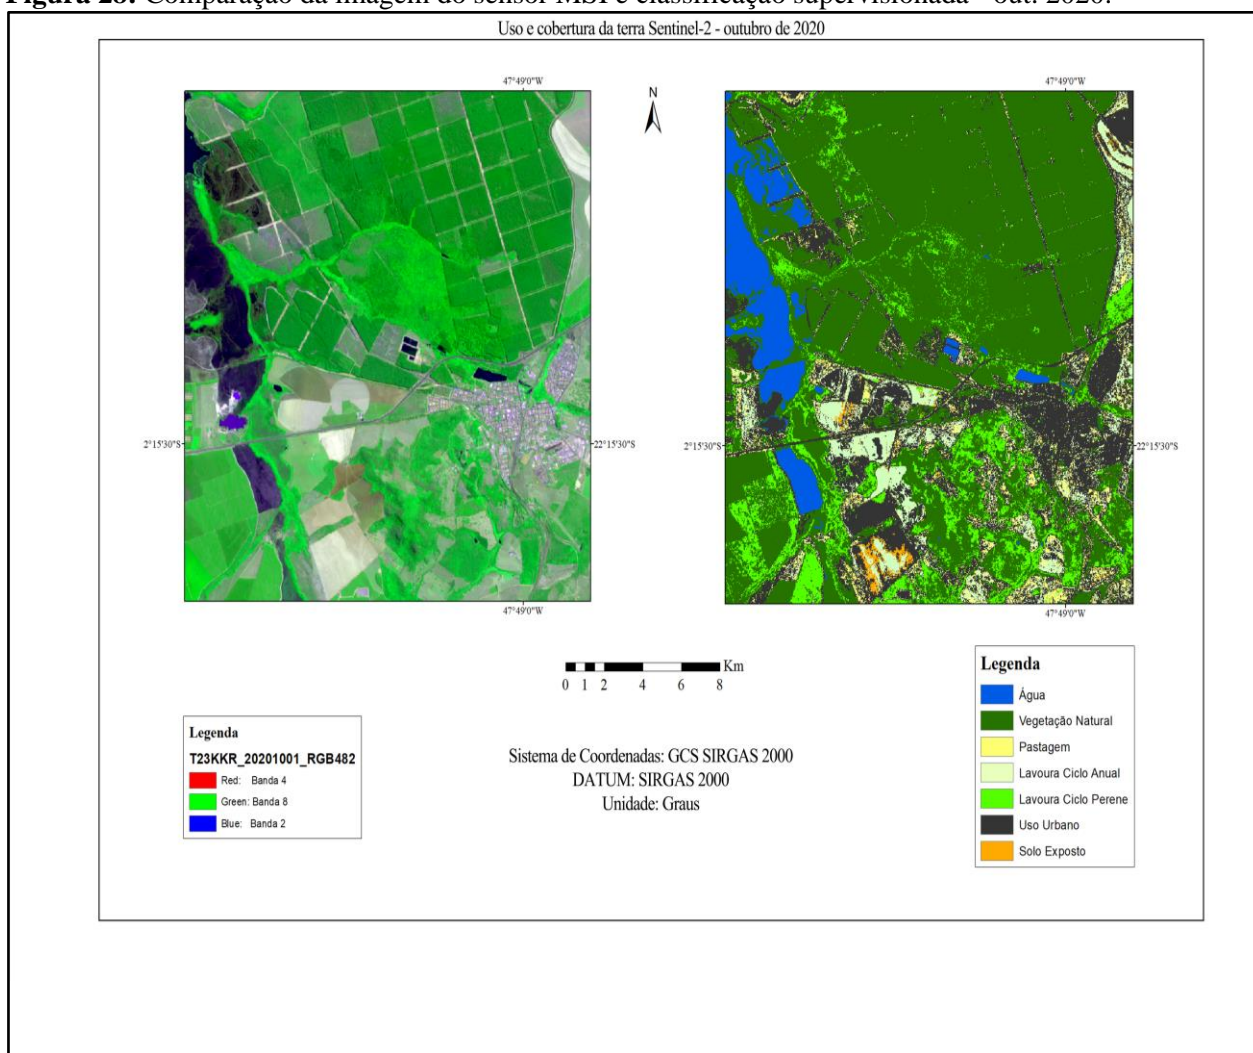


Fonte: Elaborado pelo Autor.

6.22 Resultados da classificação de imagens do sensor MSI – outubro 2020.

Na área destacada na figura 28, chama atenção a tendência do classificador considerar áreas de silvicultura como sendo pertencente a classe temática de vegetação original. Tal fato se deve a semelhança espectral entre as áreas da vegetação natural e áreas de silvicultura, ambas com vegetação densa e de grande porte. A principal diferença entre as respectivas classes consiste no elemento textural, de forma que a vegetação textural apresenta textura grosseira e irregular, enquanto a vegetação das áreas de silvicultura e cultivos perenes em geral possuem textura lisa e homogênea. O índice kappa para o processo de classificação no mês de outubro foi de 0,93 e a acurácia geral do mapeamento de 0,82. As acurácias do consumidor e do produtor foram de 0,83 e 0,74 respectivamente.

Figura 28: Comparação da imagem do sensor MSI e classificação supervisionada - out. 2020.

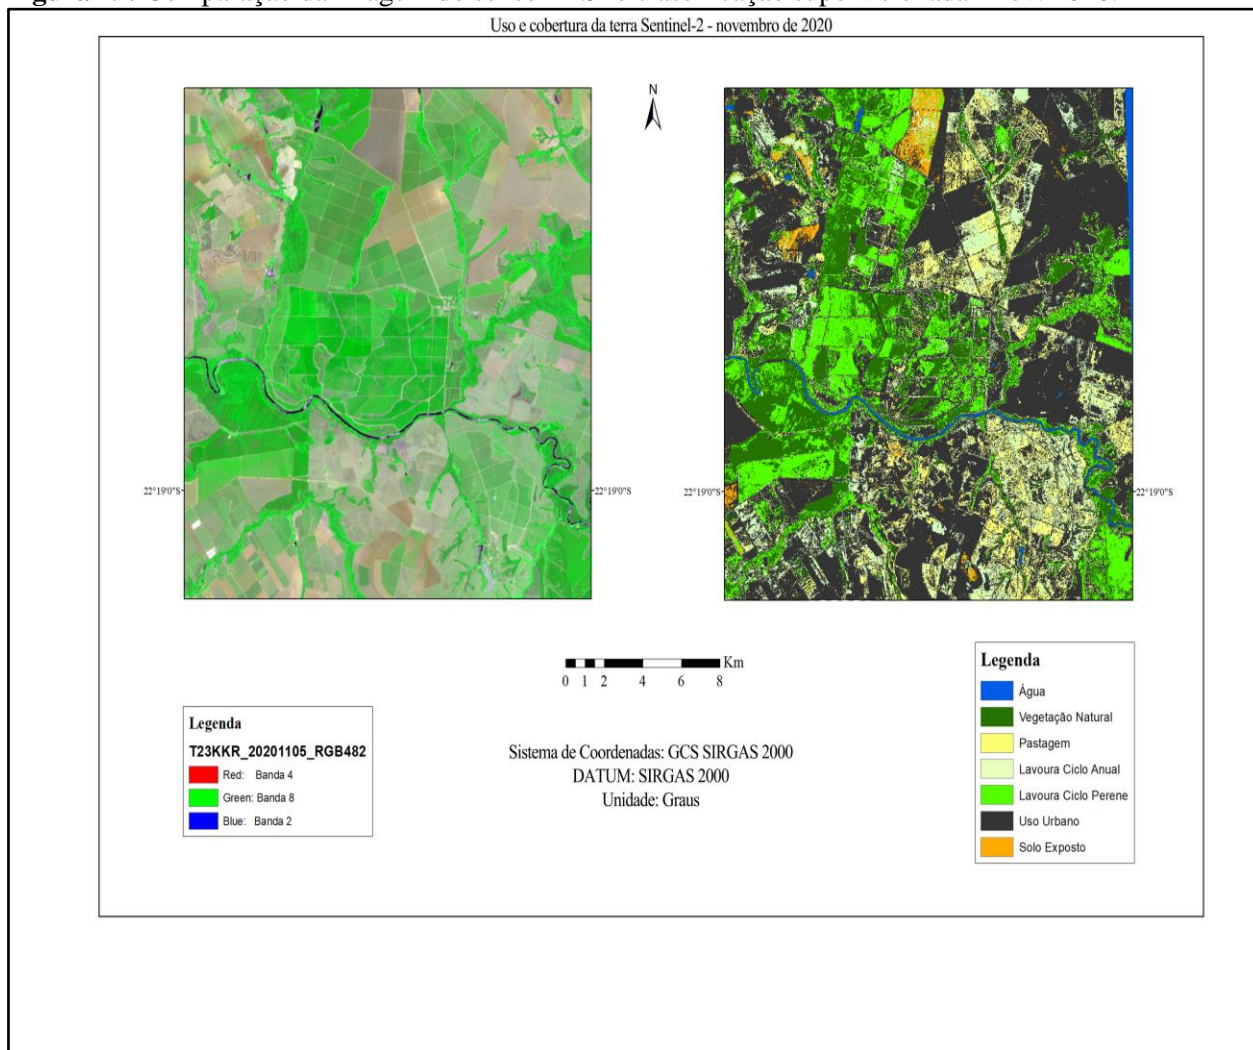


Fonte: Elaborado pelo Autor.

6.23 Resultados da classificação de imagens do sensor MSI – novembro 2020.

A imagem do mês de novembro foi analisada a partir da composição RGB em falsa cor com as bandas B4, B8 e B2. Nesta cena destaca-se a nitidez com que é registrado o rio Mogi Guaçu, de forma que foram classificadas corretamente as áreas de cultura perene, pastagens e áreas de vegetação natural. O principal erro do classificador ocorreu novamente na classificação de áreas de solo exposto como sendo áreas urbanas. O processo de classificação da imagem de novembro de 2020 obteve índice kappa de 0,96 e acurácia geral do mapeamento de 0,82. A acurácia do consumidor obteve valor de 0,83 e a acurácia do produtor obteve resultado de 0,86. A figura 29 apresenta os resultados da classificação do uso da terra para o mês de novembro.

Figura 29: Comparação da imagem do sensor MSI e classificação supervisionada - nov. 2020.

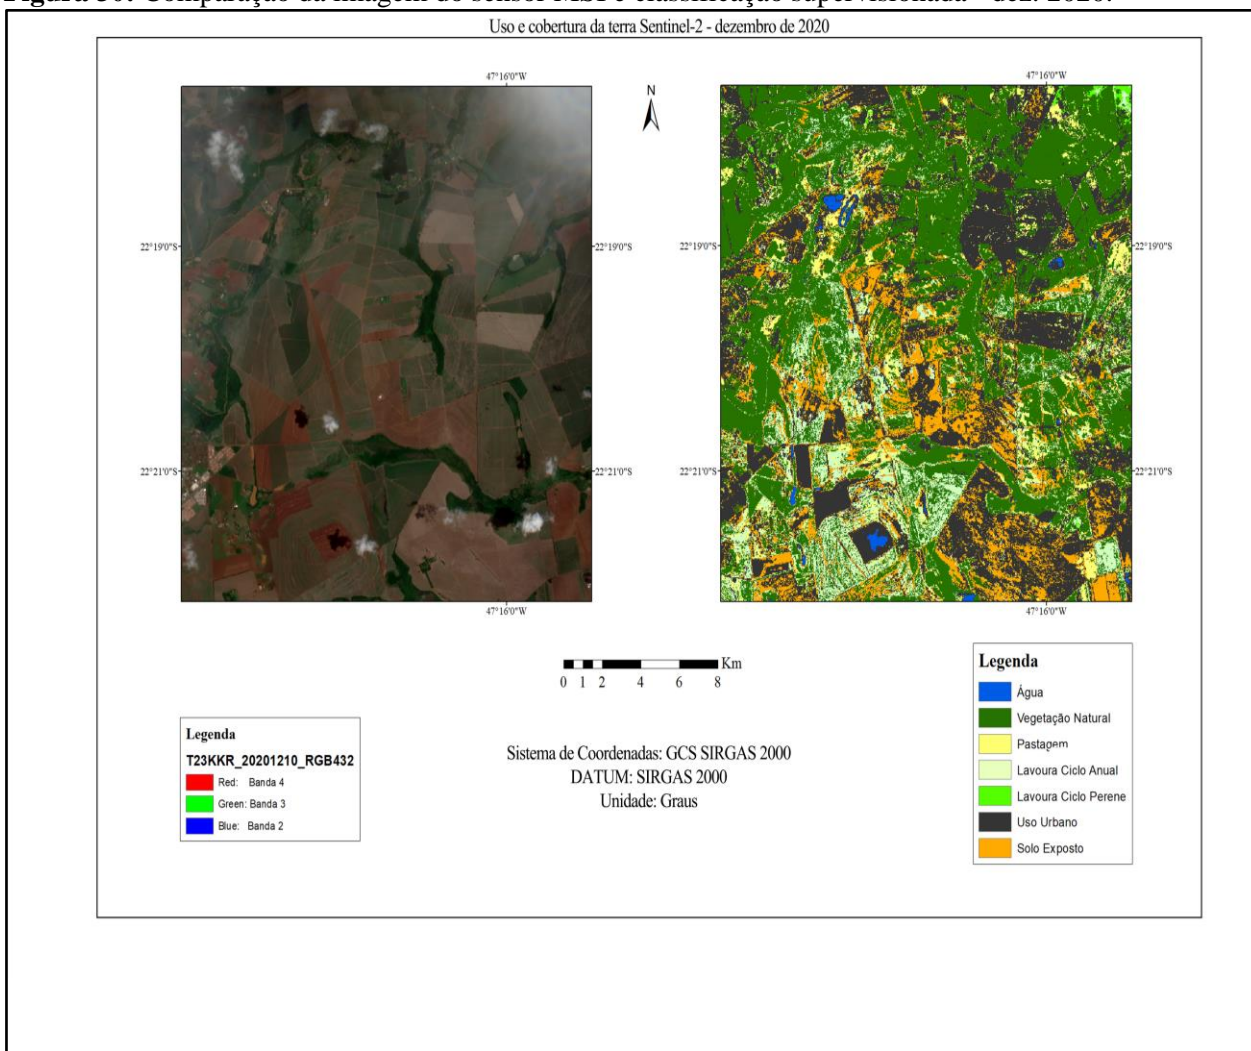


Fonte: Elaborado pelo Autor.

6.24 Resultados da classificação de imagens do sensor MSI – dezembro 2020.

Para o mês de dezembro, o processo de classificação foi feito a partir da composição RGB de cor natural com as bandas B4, B3 e B2. Nesta cena destaca-se a predominância de áreas de solo exposto que foram classificados como sendo vegetação natural. O erro se deu em razão da presença de nuvens cirrus e aerossóis em suspensão no quadrante norte da imagem. Nas áreas ao centro e ao sul o classificador obteve um bom desempenho aos classificar as áreas de solo exposto, culturas de ciclo anual e culturas de ciclo perene. O índice kappa para o mês de dezembro foi de 0,94 e acurácia geral do mapeamento de 0,88. A acurácia do consumidor obteve valor de 0,81 e a acurácia do produtor obteve resultado de 0,86. A figura 30 apresenta os resultados da classificação do uso da terra para o mês de novembro.

Figura 30: Comparação da imagem do sensor MSI e classificação supervisionada - dez. 2020.



Fonte: Elaborado pelo Autor.

6.25 Trabalho de Campo e análise do índice NDVI

O principal objetivo do trabalho de campo foi estabelecer as amostras que serviriam como verdade terrestre para fins de validação das classes de uso e cobertura da terra que foram mapeadas a partir do processo de classificação supervisionada das imagens dos sensores OLI e MSI. Originalmente estavam programados ao menos um trabalho de campo por mês ao longo de todo ano de 2020, no entanto, em decorrência das limitações impostas pelo quadro de Pandemia de Covid 19, foi realizado somente um trabalho de campo no dia 19 de julho de 2020, tendo por objetivo somente identificar a maior variedade possível de culturas agrícolas situadas no perímetro da área de estudo.

A metodologia empregada para o trabalho de campo teve por base os dados extraídos a imagem do sistema SENTINEL-2 do dia 03 de junho de 2020. A partir das bandas espectrais do sistema SENTINEL-2 foram criadas composições RGB em cor natural e em falsa cor. O objetivo das diferentes composições RGB é identificar os diferentes alvos dispostos na superfície terrestre a partir do contraste entre os alvos, de forma a facilitar a interpretação visual dos alvos registrados nas composições RGB. Desta forma, como critérios para diferenciação dos alvos, foram observadas as características de cor, textura e uniformidade dos alvos. Estes critérios serviram para selecionar as áreas de interesse analisadas em campo. A cana-de-açúcar foi identificada como sendo cultura agrícola dominante em todo o percurso realizado. Neste sentido, foi dada uma importância maior para outras culturas que fazem um contraponto em relação à predominância da cana-de-açúcar na área de estudo. Durante o trajeto, foram identificadas os seguintes cultivos agrícolas:

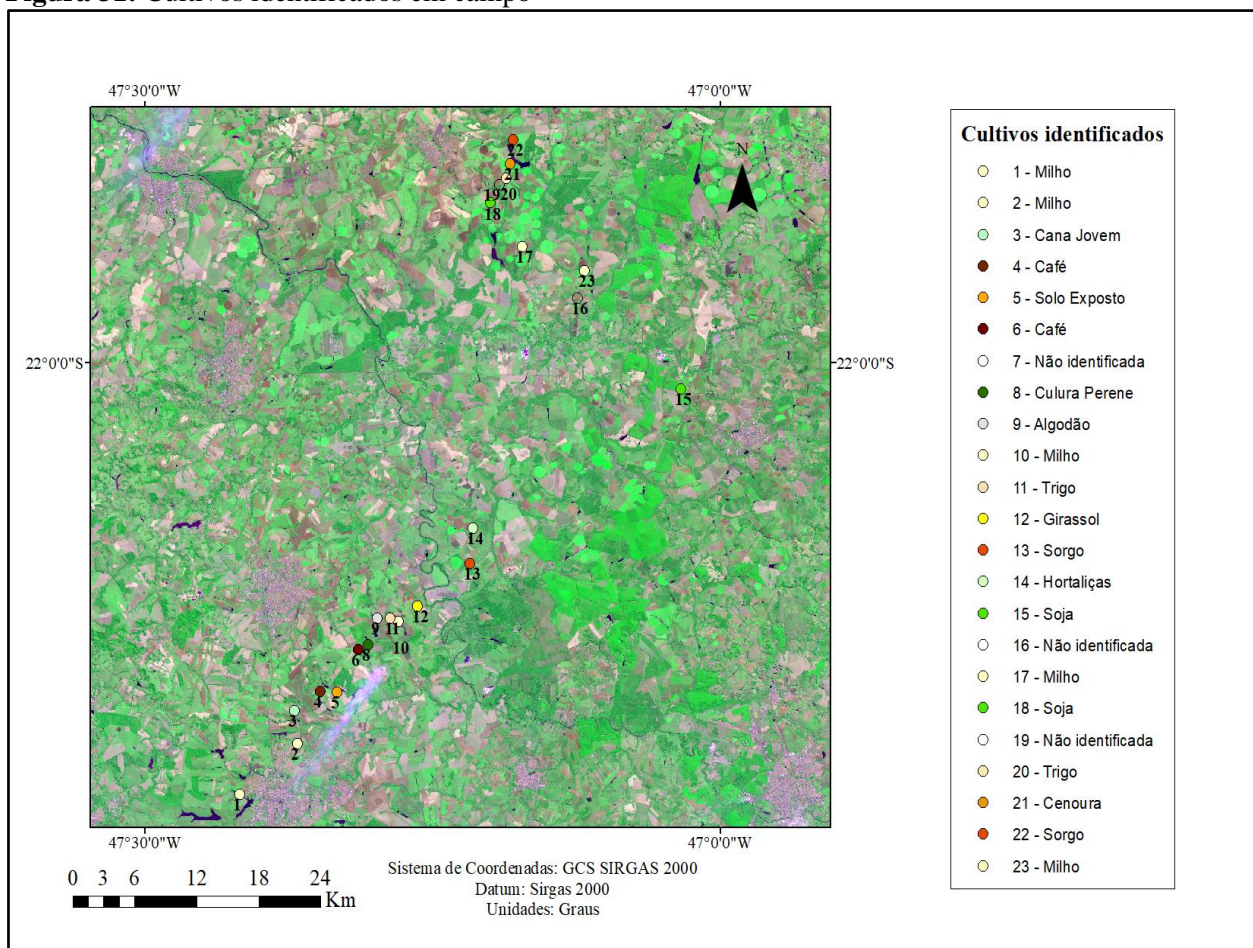
- a). Milho;
- b). Cana-de-açúcar, nos estágios inicial e final de cultivo;
- c). Café, no estágio inicial e na fase adulta;
- d). Solo exposto, coberto por palhada;
- e). Culturas perenes, representadas por citrus e silvicultura;
- f). Algodão;
- g). Trigo;
- h). Girassol;
- i). Soja;
- j). Cenoura;

i). Cultivos de hortaliças de ciclo curto;

j). Culturas não identificadas.

As culturas identificadas acima foram especializadas no da figura 31, sendo também fotografadas para fins de identificação das condições gerais do respectivo cultivo. Além das fotografias e da espacialização das culturas visitadas em campo, foi calculado o índice NDVI, que permite a estimativa do vigor de fitomassa da vegetação na área de estudo.


Figura 31: Cultivos identificados em campo



Fonte: Elaborado pelo Autor.

A figura 32 corresponde a um campo de cultivo de milho em seus estágios iniciais. Os pixels em tons de vermelho correspondem a solo exposto portanto, não deve ser considerado na escala que mede o índice NDVI na escala do mapa. Os pixels em tons de amarelo e verde representam a vegetação fotossinteticamente ativa através do índice NDVI. Nesta área foi observado valores de máximo de NDVI correspondente a quase 0,74.

Figura 32: Índice NDVI estágios iniciais do milho

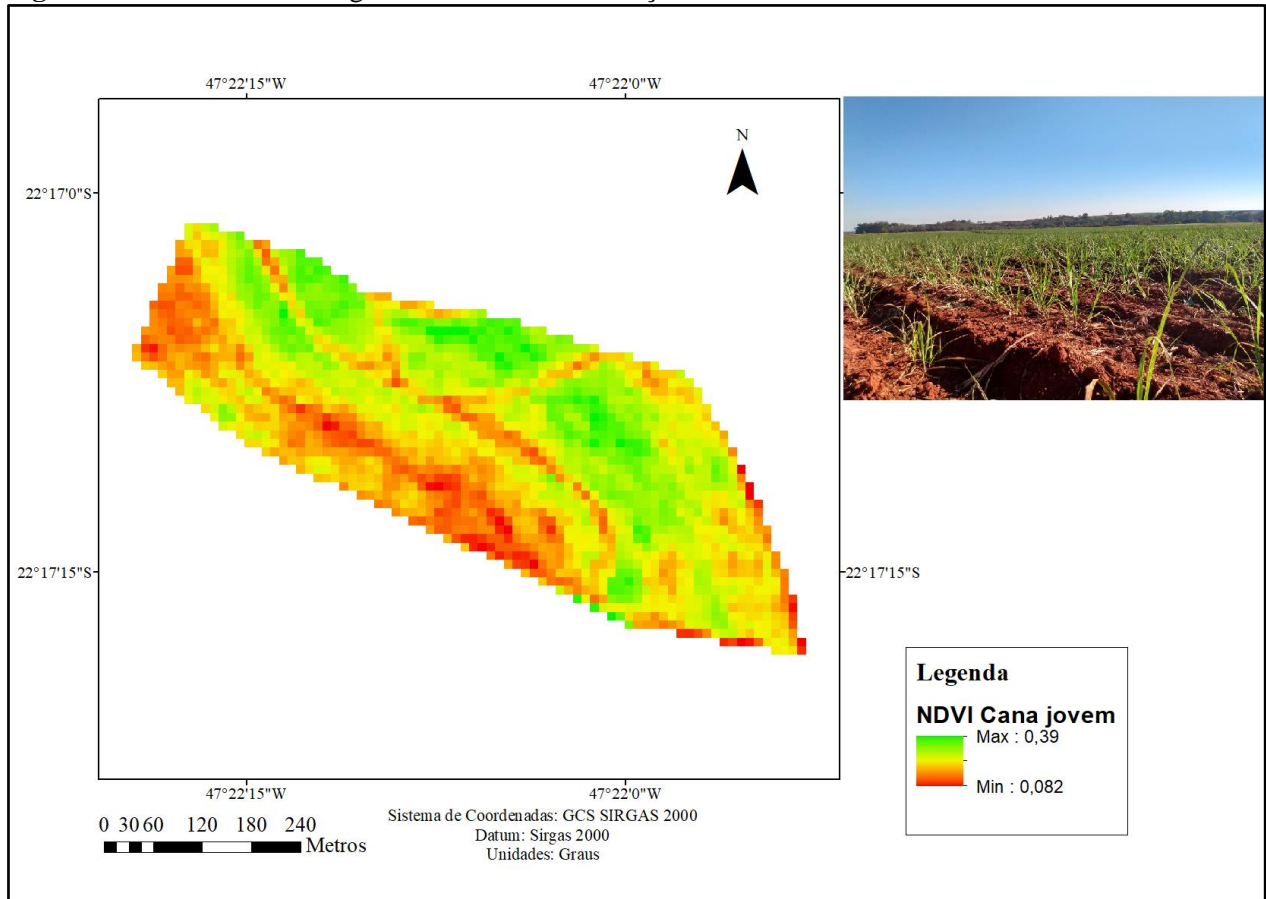


Fonte: Elaborado pelo Autor.

Considerando o comportamento espectral e temporal da cana-de-açúcar, Paixão (2018, p. 49) observou 5 fases de vigor vegetativo que refletem nos índices NDVI. Na fase 5 ocorre o crescimento gradativo dos valores dos índices. Em seguida, os valores continuam progredindo de janeiro até fevereiro, configurando a fase 1. De fevereiro a maio se concentram os valores mais altos, se apresentando de forma contínua fase 2. Os valores dos índices vão diminuindo gradualmente de maio a agosto fase 3, sendo que há uma pequena continuidade de queda e estabilização dos valores em seus estados mínimos na fase 4. A autora observou valores máximos

de 0,75 no mês de fevereiro, e valor mínimo de 0,32, no mês de setembro. Esta pesquisa observou valores máximos de NDVI de 0,39 em uma área de cana jovem, de forma que os baixos índices NDVI se explicam pela predominância do espectro refletido pelo solo em relação à cana-de-açúcar nos estágios iniciais, conforme representado na figura 33.

Figura 33: índice NDVI estágios iniciais da cana-de-açúcar



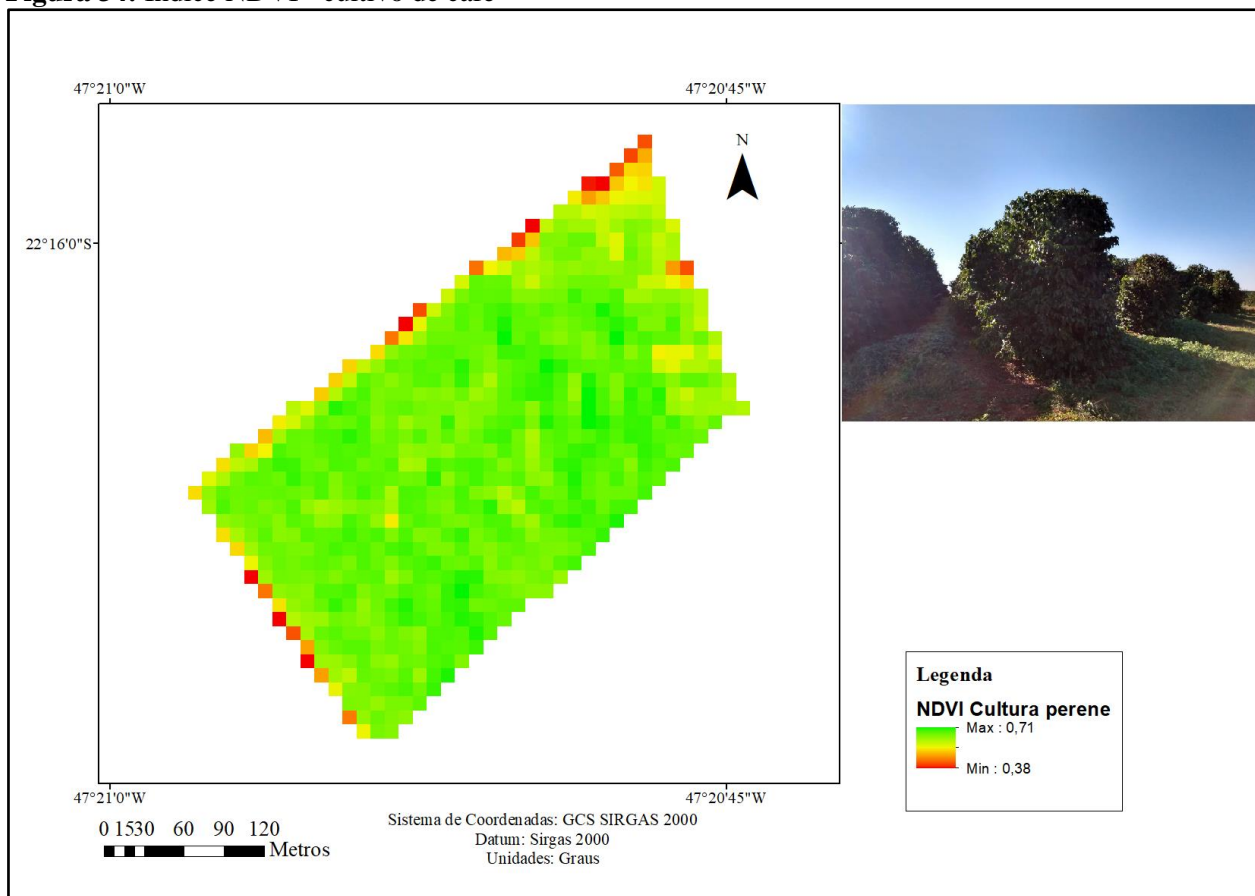
Fonte: Elaborado pelo Autor.

As figuras 34 e 35 apresentam áreas de cultivo de café, situadas no município de Araras. Em seu ciclo de desenvolvimento, o café intercala fases vegetativas e reprodutivas por cerca de 24 meses. Por ser composto por árvores de pequeno e médio porte, os cafezais apresentam elevados índices NDVI e vigor vegetativo, com uma leve queda no período entre julho e outubro (CAMARGO, A. P.; CAMARGO, M. B. P. 2001, p. 45).

Neste sentido, a vegetação em áreas de culturas perene apresenta elevados valores do índice NDVI em razão do elevado vigor vegetativo das árvores. Dessa forma, áreas como pomares,

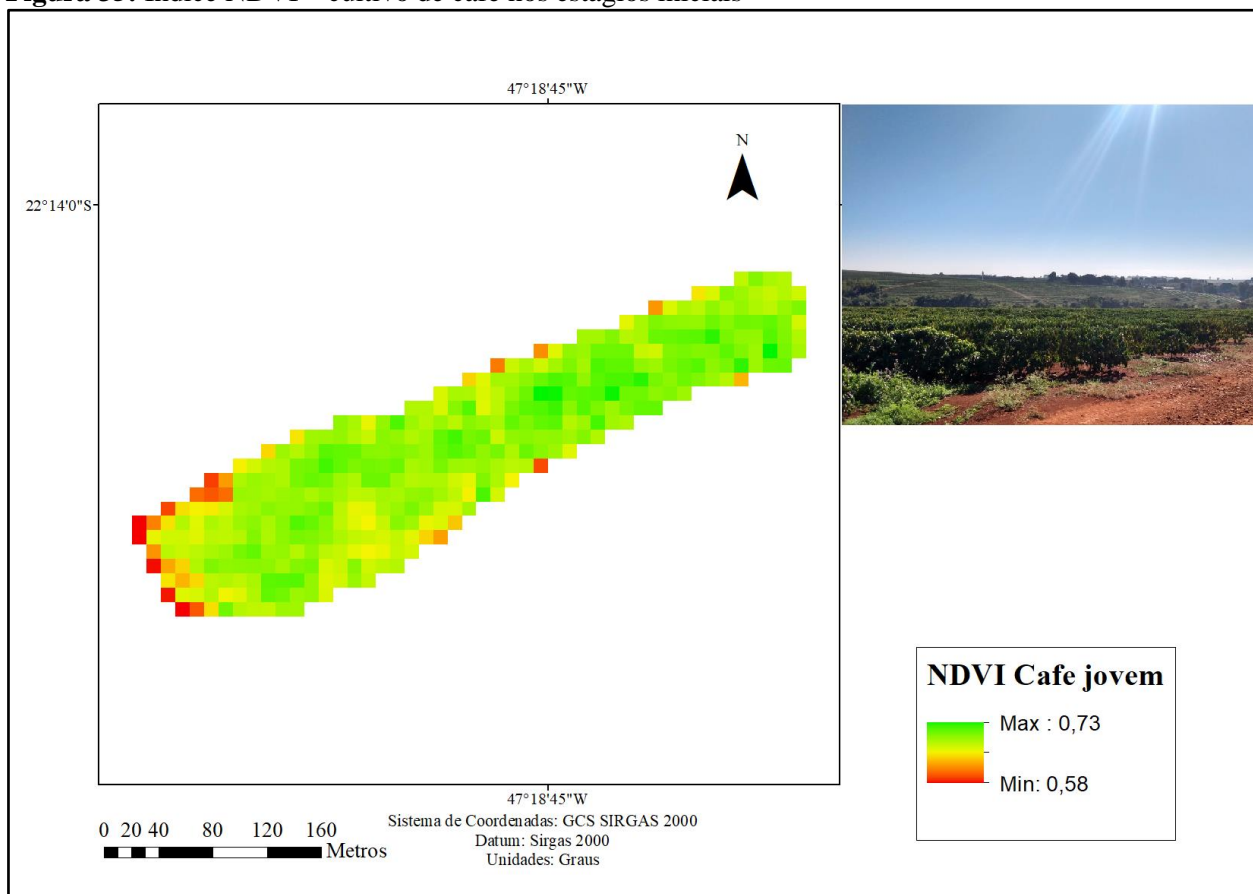
cafezais, silvicultura e vegetação natural arbórea se apresentam fotossinteticamente ativas na maior parte do tempo. Em se tratando do cultivo de café, Paixão (2018, p. 52) observou que as maiores concentrações de índices NDVI ocorrem entre janeiro e maio, com valores máximos de 0,82; e valores mínimos no mês de setembro com valor de 0,57. Os valores do índice NDVI identificados nesta pesquisa durante o mês de julho de 2022 foi de 0,71.

Figura 34: Índice NDVI - cultivo de café



Fonte: Elaborado pelo Autor.

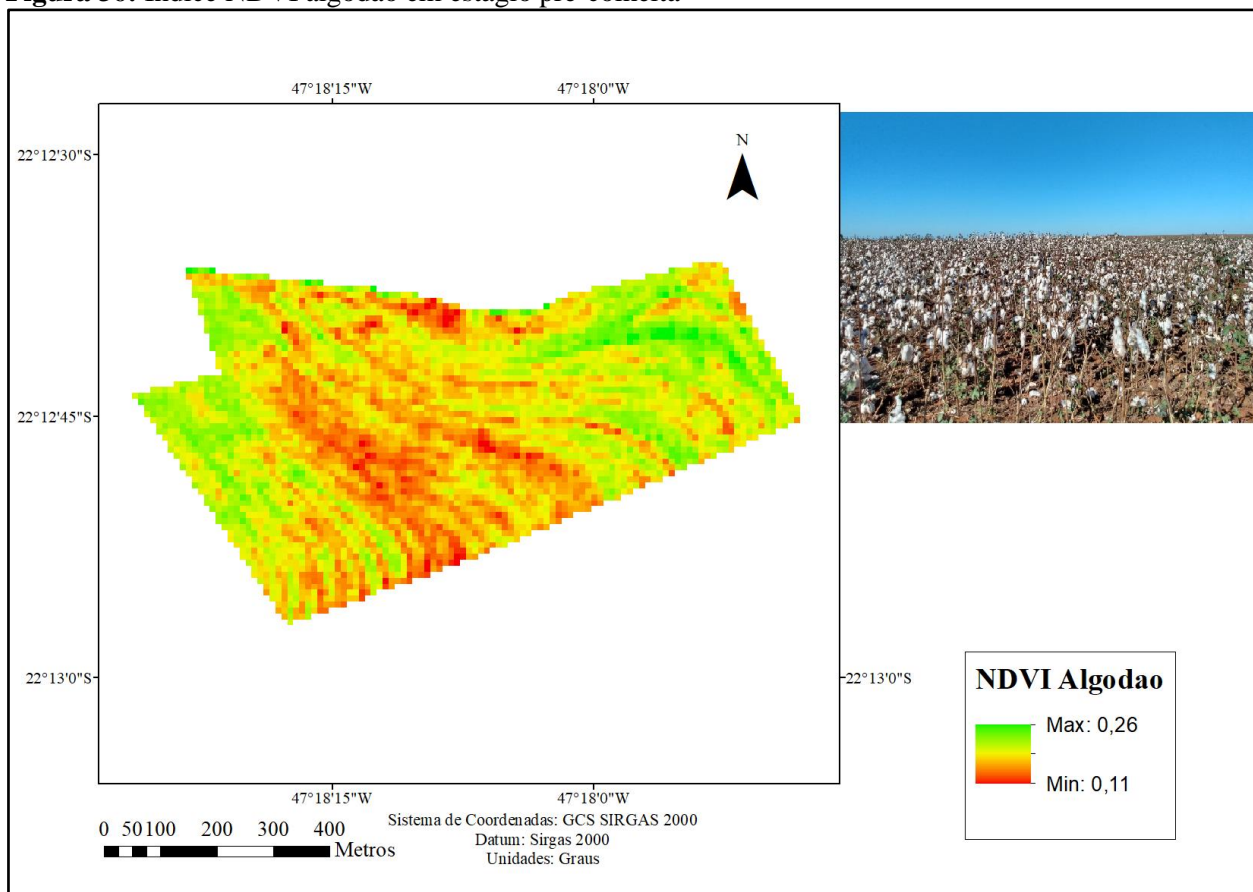
Figura 35: Índice NDVI – cultivo de café nos estágios iniciais



Fonte: Elaborado pelo Autor.

A figura 38 representa o índice NDVI para área de cultivo de algodão, situada na zona rural do município do Leme. A observa-se na imagem a predominância de tons de vermelho intercalados com tons de amarelo e verde claro que indicam baixos índices de vigor vegetativo. Os baixos índices de NDVI retratados na figura 38 consiste no comportamento esperado para o cultivo de algodão no período pré colheita, quando a planta do algodão seca e apresenta baixos índices de vigor vegetativo. Segunda a imagem do dia 03 de julho de 2021, o maior valor do índice NDVI corresponde a 0,26, enquanto que os valores mínimos situam-se na faixa de 0,11. São muito poucas as referencias sobre o monitoramento do ciclo vegetativo dos cultivos de algodão através de índices espectrais de forma a descrever o comportamento espectral do algodão durante seu ciclo vegetativo.

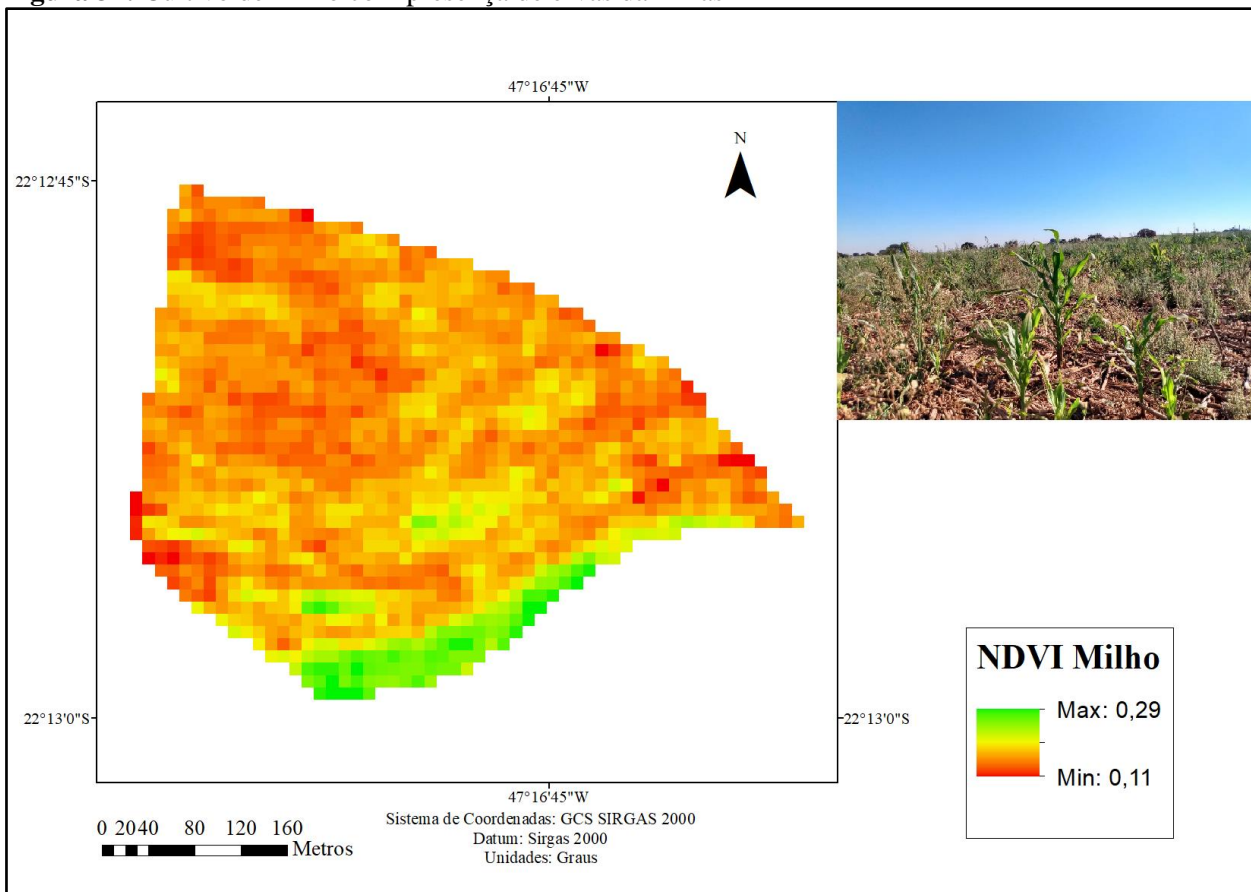
Figura 36: Índice NDVI algodão em estágio pré-colheita



Fonte: Elaborado pelo Autor.

A figura 39 apresenta um campo de cultivo de milho situado no município de Leme em estado avançado de degradação. Através da fotografia é possível observar a presença de ervas daninhas e solo exposto em detrimento do milho. Os pixels em tons de vermelho representam áreas de solo exposto, enquanto os tons de amarelo e verde claro estão relacionados com a presença das ervas daninhas em meio ao cultivo do campo de milho. Os menores índices NDVI observados nesta imagem correspondem a 0,11, e os maiores a 0,29, indicando baixos índices de vigor vegetativo.

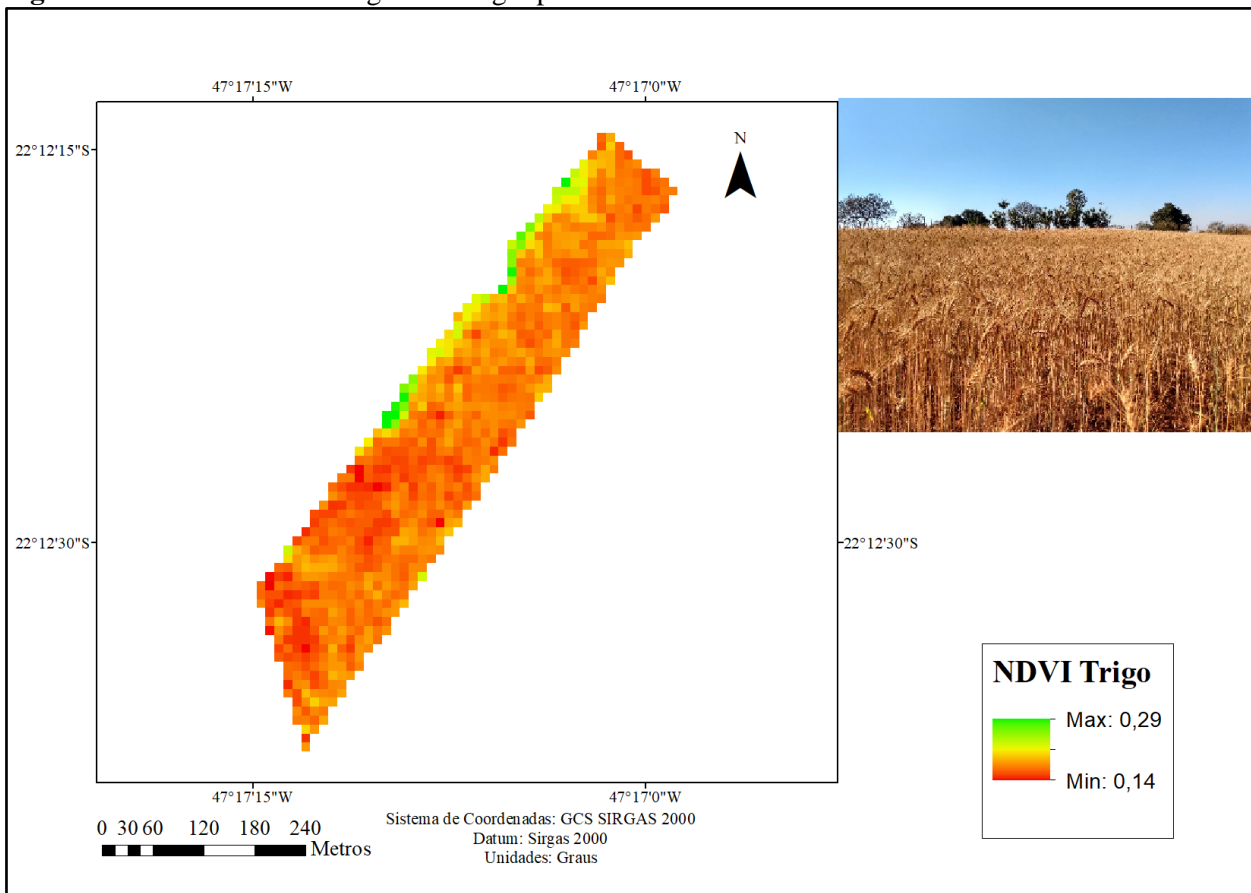
Figura 37: Cultivo de milho com presença de ervas daninhas



Fonte: Elaborado pelo Autor.

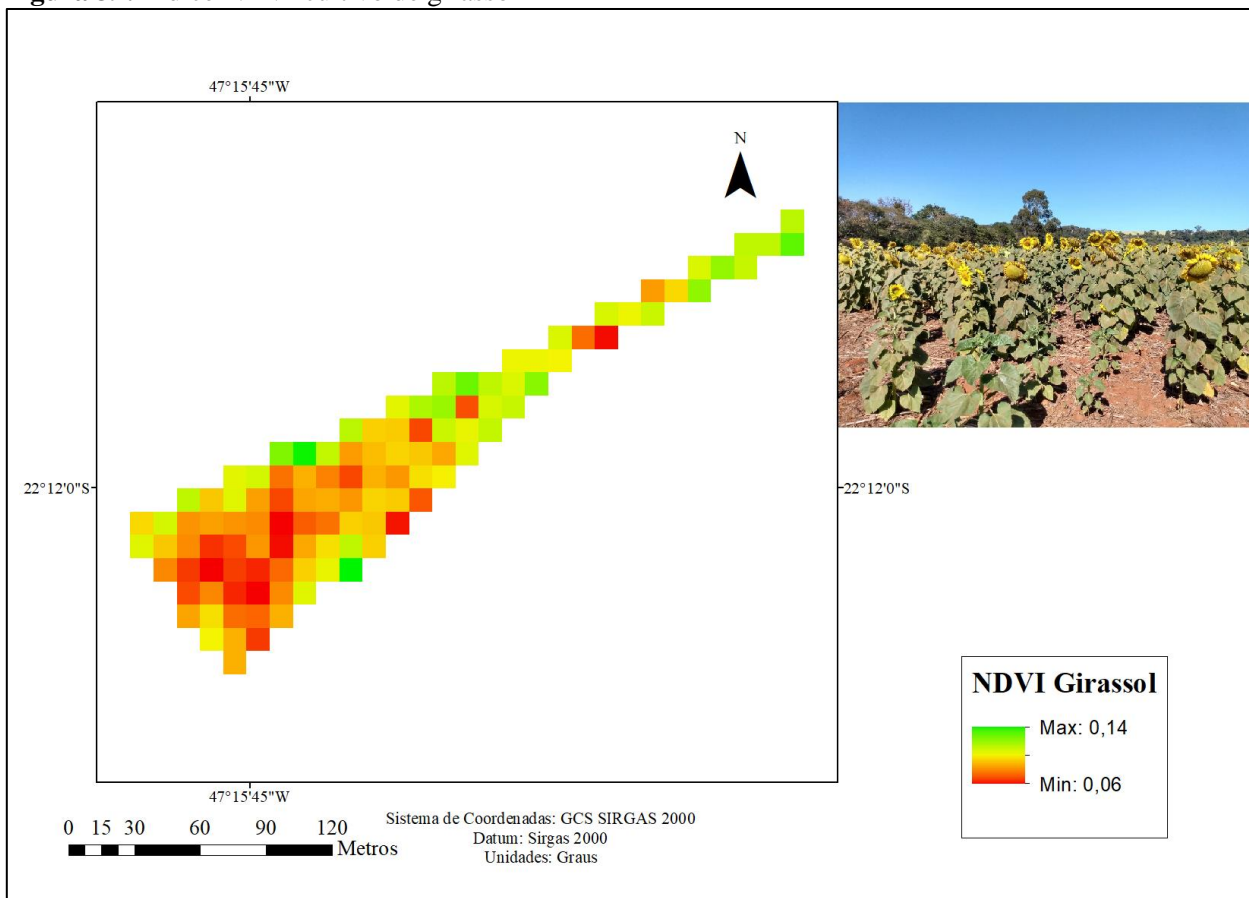
A figura 40 apresenta um campo de cultivo de trigo nos seus estágios finais, que antecedem a colheita. O campo de cultivo de trigo também está situado na zona rural do município de Leme. Através da fotografia é possível observar a homogeneidade do campo de trigo. A imagem com pixels em tons de vermelho representa a pouca presença de água e o baixo valor vegetativo do trigo na fase que antecede a colheita. Os menores índices NDVI observados no campo de cultivo de trigo correspondem a 0,14, enquanto que os maiores índices correspondem a 0,29.

Figura 38: Índice NDVI do trigo em estágio pré-colheita



Fonte: Elaborado pelo Autor.

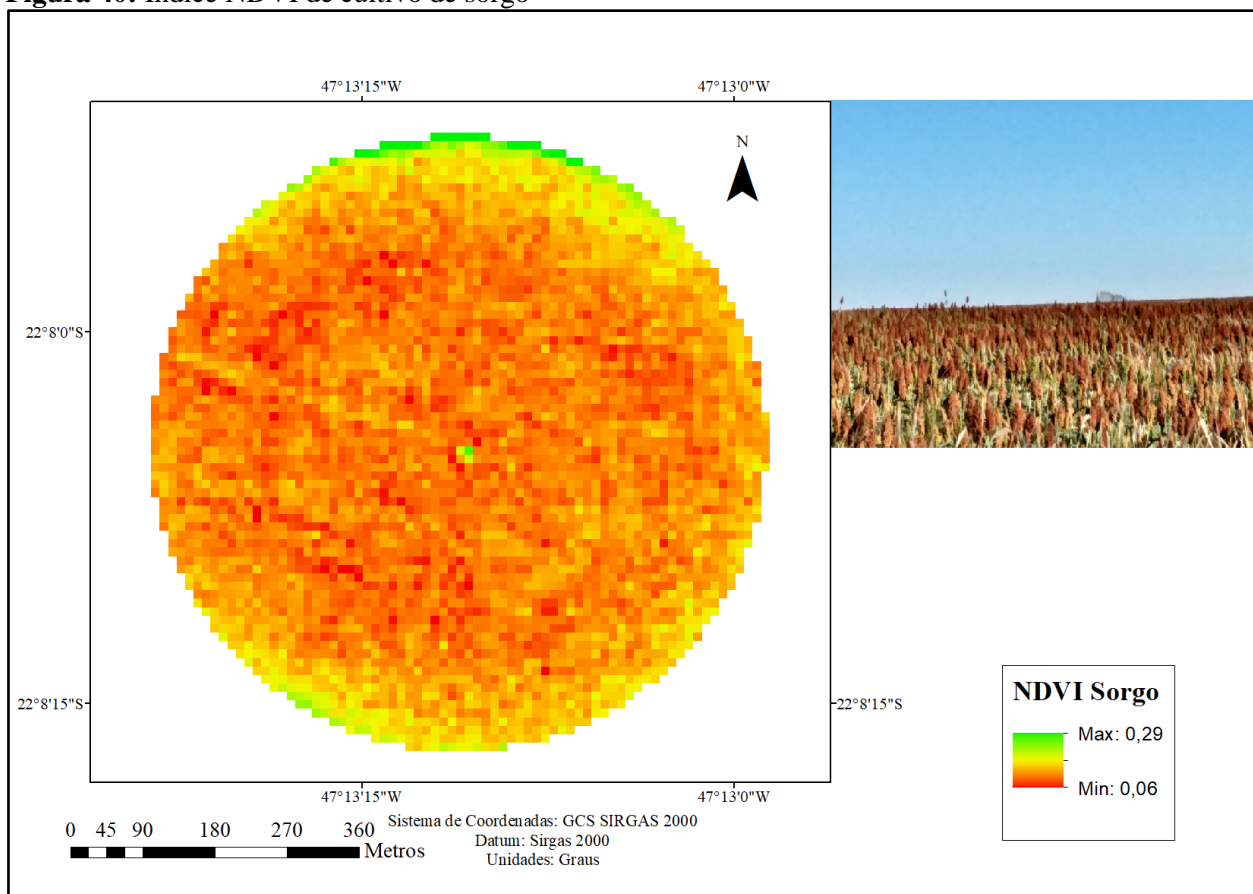
A figura 41 apresenta uma pequena área de cultivo de girassol na zona rural do município de Leme. Através da figura é possível observar os baixos índices de NDVI em função da predominância do espectro de reflexão do solo em relação à vegetação. A imagem com pixels em tons de vermelho também ocorre em função do grande espaçamento entre cada girassol, como pode ser observado na fotografia acima da escala com o índice NDVI. Os menores índices NDVI observados no campo de girassol correspondem a 0,06 enquanto que os maiores índices correspondem a 0,14.

Figura 39: Índice NDVI cultivo de girassol

Fonte: Elaborado pelo Autor.

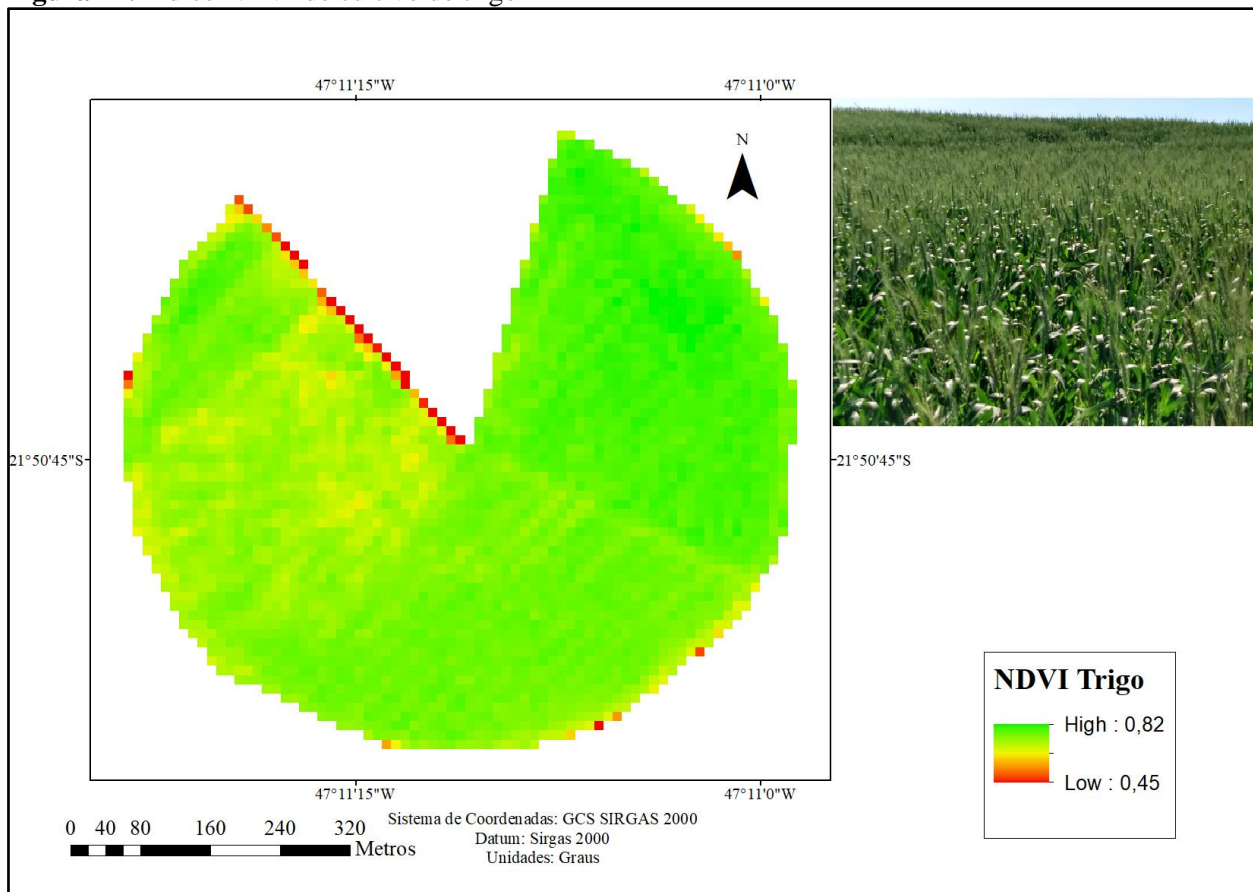
A partir da figura 42 observa-se um pivô central de cultivo de sorgo, grão muito empregado na nutrição de rebanhos. Observa-se na imagem a predominância de tons de vermelho intercalados com tons de amarelo claro que indicam baixos índices de vigor vegetativo, característico do período que antecede a colheita do sorgo. Segundo a imagem do dia 03 de julho de 2021, o maior valor do índice NDVI corresponde a 0,29, enquanto que os valores mínimos situam-se na faixa de 0,06.

Figura 40: Índice NDVI de cultivo de sorgo



Fonte: Elaborado pelo Autor.

E por fim figura 44 apresenta um campo de cultivo de trigo nos seus estágios iniciais, onde são observados elevados índices de vigor vegetativo. Através da fotografia é possível observar a homogeneidade do campo de trigo. A imagem com pixels em tons de verde representam a presença de água e as atividades metabólicas da vegetação fotossinteticamente ativa. Os menores índices NDVI observados no campo de cultivo de trigo em seu estágio inicial corresponde a 0,45. Os maiores índices de NDVI correspondem a 0,82, de forma que neste campo de cultivo de trigo foi observado o maior valor do índice NDVI.

Figura 41: índice NDVI de cultivo de trigo

Fonte: Elaborado pelo Autor.

6.26 Considerações finais

Esta pesquisa visou contribuir com proposta metodologia para a classificação do uso da terra, dando especial ênfase para o uso da terra pelas atividades agrícolas. Considerando as mudanças ambientais desencadeadas a partir das ações humanas no que diz respeito ao uso e cobertura da terra, o monitoramento de classes temáticas agrícolas se reveste de grande importância, uma vez que as atividades agrícolas são responsáveis pela segurança alimentar, pela garantia de insumos, fibras e proteínas destinadas a atender diversas necessidades das sociedades. No sentido de dar prosseguimento a essas ações, esta pesquisa irá continuar trabalhando com formas de mapeamento do uso e cobertura da terra através da exploração de uma variedade maior de métodos de classificação e a frequência dos trabalhos de campo, tendo por objetivo contribuir com soluções sustentáveis para a sociedade.

REFERÊNCIAS BIBLIOGRÁFICAS

- AB’SÁBER, A. N. **Os domínios da natureza no Brasil: potencialidades paisagísticas**. São Paulo: Ateliê Editorial, 2003
- ALMEIDA, Flávio. Marques. Fundamentos Geológicos do Relevo Paulista. **Boletim IGC**, São Paulo, n. 41, p. 169-263, 1964.
- ADAMI, M.; MELLO, M. P.; AGUIAR, D. A.; RUDORFF, B. F. T.; SOUZA, A. F. D. A.; Web Platform Development to Perform Thematic Accuracy Assessment of Sugarcane Mapping in South-Central Brazil. **Remote Sensing**. v. 4, p. 3201-3214. 2012.
- ARABI, B.; SALANA, M. H.; WERNAND, S. M. R. Wernand, Wouter Verhoef, Remote sensing of water constituent concentrations using time series of in-situ hyperspectral measurements in the Wadden Sea. **Remote Sensing of Environment**, v.216, p. 154-170, 2018.
- BAYAD, M.; CHAU, H. W. C.; MULLER, S. T. K.; CONDRON, L.; MOIR, J.; YA, L. Time series of remote sensing and water deficit to predict the occurrence of soil water repellency in New Zealand pastures. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 169, p. 292-300, 2020.
- BELGIU, M.; CSILLIK, O.; Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**. v. 204, p. 509 – 523. 2018.
- CAI, Y.; KAIYU, G.; PENG, J.; WANG, S.; SEIFERT, C.; WARDLOW, B.; LI, Z. A high-performance and in-season classification system of field-level crop types using time-series Landsat data and a machine learning approach. **Remote Sensing of Environment**. v. 210, p. 35 – 47, 2018.
- CALDARELLI, C. E.; GILIO, L.; Expansion of sugarcane industry and its effects on land use in São Paulo: Analysis from 2000 through 2015. **Land Use Policy**. v. 76, p. 264 – 274; 2018.
- CAMARGO, A. P.; CAMARGO, M. B. P. **Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil**. *Bragantia*, Campinas, v. 60, n. 1, p. 65-68, 2001.
- CARVALHO JUNIOR, O. Mapeamento da vegetação na floresta atlântica usando o classificador de árvore de decisão para integrar dados de sensoriamento remoto e modelo digital de terreno. **Revista Brasileira de Geomorfologia**. v. 26, p. 331-345. 2008.
- CHEN, Y.; LU, D.; MORAN, E.; BATISTELLA, M.; DUTRA, L. V.; SHANCHEZ, I.; SILVA, R. F. B.; HUANG, J.; BARRETO, A. J.; OLIVEIRA, M. A. F. Mapping croplands, cropping patterns, and crop types using MODIS time-series data. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 133-147, 2018.

CHRISTOFOLETTI, A. L. H. Implicações geográficas relacionada com as mudanças climáticas globais. **Boletim de Geografia Teórica**. v. 2, p. 18-31, 1993.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 2009. 183 p.

CARPENTER, S. R.; BENNETT, E. M.; Reconsideration of planetary boundary for phosphorus. **Environmental Research Letters**. v. 6, p. 09 – 14, 2011

ELLIS, E. C.; MASLIN, M.; BOIVIN, N.; BAUER, A.; Involve social scientists in defining the Anthropocene. **Nature**. v. 540, p. 192 – 193, 2016.

EYRING, V. N. P.; GILLET, K. M.; ACHUTA, R. R.; BARIMALALA, M.; BARREIRO P. N.; BELLOUIN, C.; CASSOU, P. J.; DURACK, Y.; KOSAKA, S.; MCGEGOR, S.; MIN, O. M.; SUN, Y. **Human Influence on the Climate System**. In Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press. 2021.

FITZ, P. R. Novas tecnologias e os caminhos da Ciência Geográfica. **Diálogo Tecnologia**, v. 6, p. 35 – 48, 2005.

FUSSEL, J.; DONALD, R.; HARRINGTON JR, J. A.; On Defining Remote Sensing. **Photogrammetry and Remote Sensing**. v. 59, p. 1507 – 1511. 1986.

GIRI, C. P. Brief Overview of Remote Sensing Land Cover. *In*: GIRI, C. P. **Remote Sensing of Land Cover**.. London: CRC Press Taylor & Francis group, 2012. p. 413 p. 3-11

GOOGLE. **Google Earth Engine**. Google LLC. Disponível em: <https://code.earthengine.google.com/> Acesso em: 24 novembro 2021.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R.; Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**. 202: 18 – 27. 2017.

HOOKE, R. B.; MARTÍN-DUQUE, J. F.; PEDRAZZA, J.; Land Transformation by humans: A review. **GSA Today**. 22 (12), 4 – 10, 2012.

IHLEN, V. **Landasat 8 (L8) Data Users Handbook**. Departament of the Interior, U. S Geological Survey, 2019.

IPT - INSTITUTO DE PESQUISAS TECNOLÓGICAS. **Mapa Geomorfológico do Estado de São Paulo**. São Paulo: IPT, 1981.

JESSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução: José Carlos Neves Epiphanyo *et al.* São José dos Campos, SP: Parêntese, 2011. 589p.

JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**. 50(1): 1969.

KEMP, A. C.; HAMKS, A. D.; DONNELLY., J. P.; VANE, C. H.; HORTON, B. P.; HILL, T. D.; ANISFELD, S. C.; PARNELL, A. C.; CAHILL, N.; Relative sea-level change in Connecticut (USA) during the last 2200 yrs. **Earth and Planetary Science Letters**. 428: 217 – 229. 2015.

KOFFLER, N. F. Carta de declividade da bacia do Rio Corumbataí para análise digital (SIG). **Geografia**, Rio Claro, v. 19, n. 2. p. 167-182, 1994.

KÖPPEN, W. P. **Grundriss der klimakunde**. 1931.

KUHN, T. S.; **A estrutura das revoluções científicas**. Tradução: Beatriz Viana Boeira e Nelson Boeira. São Paulo: Perspectiva, 1997. 257 p.

LANDIM, P. M. B. **O grupo Passa Dois (P) na Bacia do rio Corumbataí (SP)**. 1967. 98 f. Tese (Doutorado em Geociências e Meio Ambiente) - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 1967.

LATORRE M. L.; CARVALHO JUNIOR. O. A.; SANTOS JR, A.; SHIMABUKURO Y.E. Integração de dados de sensoriamento remoto multi resoluções para a representação da cobertura da terra utilizando campos contínuos de vegetação e classificação por árvores de decisão. **Revista Brasileira de Geofísica**. 25: 63-74. 2007.

LATHUILLIÈRE, M. J.; MIRANDA, E. J.; BULLE, C.; COUTO, E. G.; JOHNSON, S. M.; Lando Occupation and transformation impacts of soybean production in Southern Amazonia, Brazil. **Journal of Cleaner Production**. 149, 680 – 689; 2017.

LONGLEY, P.A.; GOODCHILD, M. F.; MAGUIRE, D. J.; RHIND, D. W.; **Sistemas e ciência da informação geográfica**. [Tradução André Schneider *et al.*, 3. ed. – Porto Alegre: Bookman, 2013. 540 p.

LOVELAND, T. R. History of Land-Cover Mapping. *In*: GINI, C.P.. **Remote Sensing of Land Cover**. London: CRC Press Taylor & Francis group, 2012. p. 13-19

LU, L.; WENG Q.; GUO, H.; FENG, S.; LI, F. Assessment of urban environmental change using multi-source remote sensing time series (2000–2016): A comparative analysis in selected megacities in Eurasia, **Science of The Total Environment**, v. 684, p. 567-577, 2019.

MEYER, W. B.; TURNER, B. Land-use/land-cover change: challenger for geographers. **GeoJournal**. 39, 237-240

PAIXÃO, B. **Análise da curva de crescimento vegetal em áreas agrícolas como atributo para a classificação e caracterização do uso da terra**. Trabalho de Conclusão de Curso.

IGCE/UNESP/Rio Claro - SP, p. 1-79, 2018.

PENTEADO, M. M. Implicações tectônicas na Gênese das Cuestas da Bacia de Rio Claro. **Notícias Geomorfológicas**. Campinas, v.8, n15, p.19-41, 1968.

PENTEADO, M.M. **Geomorfologia do setor centro-ocidental da depressão periférica paulista**. Instituto de Geografia, Universidade de São Paulo, São Paulo, Série Teses e Monografias 22, 86 p. 1976.

PERINOTTO, J.A.; LINO, I.C.; **Geologia, recursos minerais e passivos ambientais**. In: Atlas Ambiental da Bacia do Rio Corumbataí, Centro de Análise e Planejamento Ambiental (CEAPLA), Instituto de Geociências e Ciências Exatas, UNESP/Campus de Rio Claro. Disponível em: <http://ceapla2.rc.unesp.br/atlas/geologia.php>. Acesso em: 22 Jul. 2019.

PINTO, S. A. F. **Contribuição Metodológica para Análise de Indicadores da Erosão do Solo, Utilizando Técnicas de Sensoriamento Remoto, Geoprocessamento e Modelo Predictivo**. Tese de Livre Docência, IGCE/UNESP/Rio Claro - SP, p. 1-136, 1996.

QGIS Development Team, 2015. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>

ROOS, J, L, S. **Geografia do Brasil**. 6. ed. -. São Paulo: EDUSP, FDE, 2019.

SANTOS, Milton. **A Urbanização Brasileira**. São Paulo: Hucitec, 1993.

SANTOS, Milton. **Técnica, espaço e tempo: globalização e meio técnico-científico informacional**. São Paulo: Editora da Universidade de São Paulo, 5. ed., 2013.

SILVA JUNIOR, C. A.; NANNI, M. R.; SHAKIR, M.; TEODORO, P. E.; OLIVEIRA JUNIOR, J. F.; CEZAR, E.; GOIS, G.; LIMA, M.; WOJCIECHOWSKI, J. C.; SHITATSUCHI, L. S.; Soybean varieties discrimination using non-imaging hiperespectral sensor. **Infrared Physics & Technology**. 89, 338 – 350; 2018.

SHIMABUKURO, Y. E; PONZONI, F. J.; **Mistura Espectral: Modelo linear e aplicações**. São Paulo. Ed. Oficina de Texto, 2017

SOUZA JR, C. M.; Z. Shimbo J, Rosa MR, Parente LL, A. Alencar A, Rudorff BFT, Hasenack H, Matsumoto M, G. Ferreira L, Souza-Filho PWM, de Oliveira SW, Rocha WF, Fonseca AV, Marques CB, Diniz CG, Costa D, Monteiro D, Rosa ER, Vélez-Martin E, Weber EJ, Lenti FEB, Paternost FF, Pareyn FGC, Siqueira JV, Viera JL, Neto LCF, Saraiva MM, Sales MH, Salgado MPG, Vasconcelos R, Galano S, Mesquita VV, Azevedo T. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with LANDSAT Archive and Earth Engine. **Remote Sensing**. 2020; 12(17):2735. <https://doi.org/10.3390/rs12172735>

STEFFEN, W.; CRUTZEN, J.; MCNEILL, J. R.; The Anthropocene: Are humans now overwhelming the great forces of nature? **AMBIO: A J. of the Human Environment**. 36(8): 614

– 621. 2007.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the LANDSAT 8/OLI land surface reflectance product **Remote Sensing of Environment**. Volume 185, p.46-56, 2016.

WANG, S.; AZZARI, G.; LOBELL, D. B.; Crop type mapping without field-level labels: Random forest transfer and unsupervised clustering techniques. **Remote Sensing of Environment**. 222, 303 – 317, 2019.

WATERS, C. N.; ZALASIEWICZ, J.; SUMMERHAYES, C. P.; BARNOSKY, A. D.; POIRIER, C.; GALUSZKA, A.; CEARRETA, A.; EDGWORTH, M.; ELLIS, E. C.; ELLIS, M.; JEANDEL, C.; LEINFELDER, R.; McNEILL, J. R.; RICHTER, B. D.; STEFFEN, W.; SYVITSKI, J.; VIDAS, D.; WAGREICH, M.; WILLIAMS, M.; ZHISHENG, W.; GRINEVALD, J.; ODADA, E.; ORESKES, N.; WOLFE, A. P.; The Anthropocene is functionally and stratigraphically distinct from the Holocene distinct from Holocene. **Science**. 351 (6269), 138 – 147, 2016.

WRIGHT, C.; GALLANT A. Improved wetland remote sensing in Yellowstone National Park using classification trees to combine TM imagery and ancillary environmental data. **Remote Sensing of Environment**. 107: 582-605. 2007.

WU, B.; GOMMERS, R.; ZHANG, M.; ZENG, H.; YAN, N.; ZOU, W.; ZHENG, Y.; ZHANG, N.; CHANG, S.; XING, Q.; VAN HEIJDEN, A. Global Crop Monitoring: A Satellite-Based Hierarchical Approach. **Remote Sensing**. v.7, p. 3907-393, 2015.

WULDER, M. A.; WHITE, J. C.; LOVELAND, T. R.; WOODCOCK C. E.; BELWARD, A. S.; COHEN, W. B.; FOSNIGHT, E. A.; SHAW, J.; MASEK, J. G.; ROY, D. P. The global LANDSAT archive: Status, consolidation, and direction, **Remote Sensing of Environment**. v. 185, p. 217 – 283, 2016.

YANG, C.; EVERITT, J. H.; FLETCHER, R. S.; MURDEN, D. Using high resolution QuickBird imagery for crop identification and area estimation. **Geocarto International**. v. 22, p. 219-233, 2007.

YANG, G.; ZHAO, Y.; XING. Z.; XING, H.; FU, Y.; GUILIN L.; XINYI, K.; XIN, M. Understanding the changes in spatial fairness of urban greenery using time-series remote sensing images: A case study of Guangdong-Hong Kong-Macao Greater Bay. **Science of The Total Environment**. v. 715, 2020.

ZALASIEWICZ, J. WILLIAMS, C. N.; Can an Anthropocene Series be defined and recognized? In **A Stratigraphical Basis for the Anthropocene**. (Geological Society). pp. 39 – 53. 2014.

ZALASIEWICZ, J.; WATERS, C. N.; SUMMERHAYES, C. P.; WOLFE, P. A.; BARNOSKY, A. D.; CEARRETA, A.; CRUTZEN, P.; ELLIS, E. C.; FAIRCHILD, I. J.; GALUSZKA, A.; HAFF, P.; HAJDAS, I.; HEAD, M. J.; SUL, J. A. I.; JEANDEL, C.; LEINFELDER, R.; McNEILL, J. R.; NEAL, C.; ODADA, E.; ORESKES, N.; STEFFEN, W.; SYVITSKI, J.; VIDAS, D.; WAGREICH, M.; WILLIAND, M.; The Working Group of Anthropocene: Summary of evidence

and interim recommendations. **Anthropocene**. 19: 55 – 60. 2017.

ZALASIEWICZ, J.; WATERS, C. N.; WILLIAMS, M.; BARNOSKY, A. D.; CEARRETA, A.; CRUTZEN, P.; ELLIS E.; ELLIS, M.A.; FAIRCHILD, I. J.; GRINEVALD, J.; HAFF, P. K.; HAJDAS, I.; LEINFELDER, R.; MC NEIL, J.; ODADA, E. O.; POIRIER, C.; RICHTER, D.; STEFFEN, W.; SUMMERHAYES, C.; SYVITSKI, J. P. M.; VIDAS, D.; WAGREICH, M.; WING, S. L.; WOLFE, A. P.; ZHISHENG, A.; ORESKES, N.; When did Anthropocene begin? A mid-twentieth century boundary level is stratigraphically optimal. **Quaternary International**. 338: 196 – 203. 2015.

BIBLIOGRAFIA CONSULTADA

FERREIRA, M.V. Detecção de anomalias vegetais em talhões canavieiros por meio de modelagem espaço temporal do vigor relativo de fitomassa In. - Congresso Brasileiro de Agricultura de Precisão ConBAP. Goiânia – GO, 2016. Anais do Congresso Brasileiro de Agricultura de Precisão. Centro de Eventos da UFG. p. 166 a 170, 2016

FORMAGGIO, A. R.; SANCHES, I.D. **Sensoriamento remoto em Agricultura**. São Paulo. Ed. Oficina de Texto, 2017.

GERS, C.; SCHMIDT, E.; **Using SPOT 4 Satellite Imagery to Monitor Area Harvested by Small Scale Sugarcane Farmers at Umfolozi**. In: 75th South Africa Sugar Technologists' Association (SASTA), 2001, Durban, South Africa. Proceedings. p.28–33

GEHRELS, R.; WOODWORTH, P. L.; When did modern rates of sealevel rise start? **Global Planetary Change**. V. 100, p. 263 – 277. 2013.

MOREL, J.; TODOROFF, P.; BÉGUÉ, A.; BURY, A.; MARTINÉ, J.-F.; PETIT, M.; Toward a Satellite-Based System of Sugarcane Yield Estimation and Forecasting in Smallholder Farming Conditions: A Case Study on Reunion Island. **Remote Sensing**. 6(7): 6620-6635. 2014.

OLIVEIRA, J. B.; PRADO, H.; **Levantamento pedológico semidetalhado do Estado de São Paulo: quadrícula de São Carlos**. Escala 1:100.000. Campinas: Instituto Agrônômico, 1981.

RUDORFF, B. F. T.; AGUIAR, D. A.; SILVA, W. F.; SUGAWARA, L. M.; ADAMI, M.; MOREIRA, M. A. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using LANDSAT Data. **Remote Sensing**. 2(4): 1057-1076. 2010.

VIEIRA, M. A.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object Based Image Analysis and Data Mining applied to a remotely sensed LANDSAT time-series to map sugarcane over large areas. **Remote Sensing of Environment**. Volume 123(0): 553-562; 2012.