



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIAS E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E  
TECNOLOGIAS DA GEOINFORMAÇÃO

DANIEL SILVA VERAS

**ANÁLISE TEMPORAL MULTIFONTE E MULTIESPECTRAL DA COBETURA  
VEGETAL DO ESTUÁRIO DO RIO SIRINHAÉM – PE**

Recife  
2022

DANIEL SILVA VERAS

**ANÁLISE TEMPORAL MULTIFONTE E MULTIESPECTRAL DA COBETURA  
VEGETAL DO ESTUÁRIO DO RIO SIRINHAÉM – PE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, Centro de Tecnologias e Geociências, como requisito parcial para obtenção do título de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

**Área de concentração:** Ciências Geodésicas e Tecnologias da Geoinformação

**Orientador:** Prof. Dr. João Rodrigues Tavares Júnior

Recife  
2022

Catálogo na fonte:  
Bibliotecário Josias Machado, CRB-4 / 1690

V476a Veras, Daniel Silva.  
Análise temporal multifonte e multiespectral da cobertura vegetal do estuário do Rio Sirinhaém – PE / Daniel Silva Veras. – 2022.  
113 f.: il., figs., tabs., abrev. e sigl.

Orientador: Prof. Dr. João Rodrigues Tavares Junior.  
Dissertação (mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação 2022.  
Inclui referências.

1. Ciências Geodésicas 2. Análise multiespectral e multifonte 3. Sensoriamento remoto. 4. Mapbiomas. 5. CBERS. 6. Landsat. 7 Sentinel-2. 8. Rio Sirinhaém - cobertura vegetal. I. Tavares Junior, João Rodrigues (orientador). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2022-313

DANIEL SILVA VERAS

**ANÁLISE TEMPORAL MULTIFONTE E MULTIESPECTRAL DA COBETURA  
VEGETAL DO ESTUÁRIO DO RIO SIRINHAÉM – PE**

**Dissertação** apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, Centro de Tecnologias e Geociências, como requisito parcial para obtenção do título de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: 19 / 04 / 2022.

**BANCA EXAMINADORA**

---

Prof. Dr. João Rodrigues Tavares Júnior (Orientador)  
Universidade Federal de Pernambuco

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Janaína Maria de Oliveira de Assis (Examinadora Externa)  
Universidade Federal de Pernambuco

---

Prof. Dr. Rafael Rodrigues da Silva (Examinador Externo)  
Instituto de Tecnologia de Pernambuco

À minha família querida: minha esposa (Lauriane Nascimento) e minhas filhas (Raquel, Clarisse e Stella). Estes são minha base, minha estrutura e o motivo pelo qual dou o meu melhor.

## AGRADECIMENTOS

À Deus, por ter me dado capacidade de chegar até aqui. Pelos momentos bons e ruins que me proporcionaram experiência necessárias. Por abençoar a mim e as pessoas que amo. Obrigado Deus.

A todos os professores e funcionários do Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da UFPE, em especial às professoras Andréa Flávia Tenório Carneiro e Ana Lúcia Bezerra Candeias, com quem tivemos a possibilidade de maior contato. Sou grato por todo auxílio e contribuição na minha formação.

Ao meu orientador, prof. Dr. João Rodrigues Tavares Junior, por ensinar, confiar e apoiar o meu trabalho. Não só pela competência e domínio do assunto, mas também por demonstrar excelentes qualidades como ser humano. Muito obrigado.

Aos membros da banca, Prof<sup>ra</sup>. Dr<sup>a</sup>. Janaína Maria de Oliveira de Assis, Prof. Dr. Rafael Silva dos Anjos e Prof. Dr. Rafael Rodrigues da Silva, pelas importantes contribuições e oportunidade de aprendizado.

Aos companheiros de curso. Em especial à Thaisa M. S. França e Uilka E. Tavares, pela parceria e grande ajuda durante as disciplinas do curso.

Ao colega Reurysson C. S. Morais, pelo apoio na revisão do texto final desse trabalho.

Ao Instituto Federal do Piauí, por ter concedido afastamento das atividades docentes para que eu pudesse me dedicar exclusivamente às atividades da pós-graduação.

À minha esposa, Lauriane Nascimento, por todo apoio e incentivo.

A todos que, de alguma maneira, puderam contribuir com o desenvolvimento desse trabalho.

## RESUMO

A abordagem multisensor pode representar vantagens por conta da maior quantidade de imagens disponíveis num mesmo período de interesse e também por contribuir para aquisição de imagens livres de nuvens e/ou compatibilização de datas de aquisição mais próximas, dois aspectos importantes em estudos multi-temporais. Avaliar essa possibilidade em sistemas com cobertura global e acesso livre e aberto, como os dados Landsat, CBERS e Sentinel-2, é um aspecto adicional que vem contribuir com a comunidade usuária desses dados. Esta pesquisa propõe realizar análise temporal (anos 2000 a 2020) multifonte (dados Landsat, CBERS e Sentinel-2) da cobertura vegetal de mangue do estuário do Rio Sirinhaém, litoral sul do Estado de Pernambuco por meio de índices físicos de sensoriamento remoto (NDVI, SAVI, EVI, VARIGreen e NDWI). Além dos índices em resolução nativa dos sensores, também foram gerados índices a partir das imagens fusionadas. Os índices gerados foram comparados e analisados via espacialização e geração de gráficos do tipo *box plot* e a partir dessas análises procedemos o mapeamento da cobertura vegetal por meio do fatiamento das imagens. Os resultados encontrados nos permitem concluir que, à despeito de área de estudo encontrar-se situada numa Área de Proteção Ambiental (APA estuariana dos rios Sirinhaém e Maracaípe), encontra-se em curso um processo gradual de ocupação e exploração das áreas de entorno das florestas de mangue, com efeitos práticos na redução da cobertura vegetal. Essa diminuição se dá principalmente com a substituição da cobertura vegetal nas bordas da área para o cultivo agrícola de cana-de-açúcar e/ou criação de pastagens para animais. As maiores variações na cobertura vegetal se deram no primeiro intervalo da pesquisa, entre os anos de 2000 e 2010. A metodologia apresentada nesse estudo permitiu obter ótimos índices de concordância (82,44%) quando comparamos com mapeamento do projeto MapBiomass. Na análise espectral da cobertura vegetal, o índice NDVI apresentou melhor performance em promover, virtualmente, plena separação entre as duas tipologias de mangue e dos alvos de vegetação para os demais, e por isso foram utilizados na geração dos mapas de cobertura vegetal; Em relação aos índices calculados a partir das imagens fusionadas, estes agregaram melhorias no contorno visual das feições, com apresentação de bordas e contornos mais suaves e melhor definidos, mas no geral, apresentaram similaridade com os dados em resolução nativa quanto ao comportamento espectral dos alvos estudados; Os sensores MUX e WPM a bordo do novo satélite CBERS-4A apresentaram resultados similares aos observados nos sensores OLI/LANDSAT-8 e MSI/Sentinel-2.

**Palavras-chave:** análise multiespectral e multifonte; sensoriamento remoto; Mapbiomas; CBERS; landsat; sentinel-2; Rio Sirinhaém – cobertura vegetal.

## ABSTRACT

The multisensor approach can represent advantages due to the greater number of images available in the same period of interest and also for contributing to the acquisition of cloud-free images and matching of acquisition dates closer, two important aspects in multi-temporal studies. Assess this possibility in systems with global coverage and free and open access, such as Landsat, CBERS and Sentinel-2 data, is an additional aspect that contributes to the community that uses this data. This research proposes to perform temporal analysis (2000 to 2020) multisource (Landsat, CBERS and Sentinel-2 data) of mangrove vegetation cover in the Sirinhaém River estuary, southern coast of the State of Pernambuco through physical remote sensing indices (NDVI , SAVI, EVI, VARIgreen and NDWI). In addition to the native resolution indices of the sensors, indexes were also generated from the merged images. The generated indices were compared and analyzed via spatialization and generation of box plot graphics and from these analyzes we proceeded to map the vegetation cover by slicing the images. The results found allow us to conclude that, despite the study area being located in an Environmental Protection Area (APA estuariana dos rios Sirinhaém e Maracaípe), a gradual process of occupation and exploitation of the areas surrounding the mangrove forests, with practical effects on the reduction of vegetation cover. This decrease is mainly due to the replacement of vegetation cover on the edges of the area for the agricultural cultivation of sugarcane and/or the creation of pastures for animals. The greatest variations in vegetation cover occurred in the first interval of the research, between the years 2000 and 2010. The methodology presented in this study allowed obtaining excellent concordance rates (82.44%) when compared to mapping from the MapBiomass project. In the spectral analysis of the vegetation cover, the NDVI index showed better performance in promoting, virtually, full separation between the two mangrove typologies and the vegetation targets for the others, and therefore they were used in the generation of vegetation cover maps; Regarding the indices calculated from the merged images, these added improvements in the visual contour of the features, with smoother and better defined edges and contours, but in general, they presented similarity with the data in native resolution regarding the spectral behavior of the targets studied; The MUX and WPM sensors aboard the new CBERS-4A satellite showed similar results to those observed in the OLI/LANDSAT-8 and MSI/Sentinel-2 sensors.

**Keywords:** multispectral and multisource analysis; remote sensing; CBERS; landsat; sentinel-2; Mapbiomas; Sirinhaém river - vegetation coverage.

## LISTA DE ILUSTRAÇÕES

Figura 1 –	Distribuição dos manguezais no mundo .....	21
Figura 2 –	Curva espectral típica de uma folha verde .....	24
Figura 3 –	Curva espectral da água nos estados líquido, gasoso (nuvem) e sólido (neve) .....	25
Figura 4 –	Localização da área de estudo .....	34
Figura 5 –	Bacia hidrográfica do Rio Sirinhaém .....	35
Figura 6 –	Fluxograma da metodologia de aquisição e processamento dos dados .....	36
Quadro 1 –	Imagens empregadas na pesquisa .....	38
Gráfico 1 –	Valores mensais de precipitação na área de estudo, anos 2000, 2010 e 2020 .....	39
Figura 7 –	Valores diários de precipitação nas datas de aquisição das imagens ...	39
Figura 8 –	Ferramenta Georreferenciador do <i>software</i> QGIS. ....	40
Figura 9 –	Comparação entre a imagem referência e a imagem ajustada pelo processo de normalização radiométrica .....	46
Figura 10 –	Interface das ferramentas <i>Superimpose</i> e <i>Pansharpening</i> no <i>software</i> QGIS .....	47
Quadro 2 –	Índices espectrais utilizados no trabalho .....	48
Quadro 3 –	Índices gerados e respectivas nomenclaturas utilizadas na pesquisa ....	49
Quadro 4 –	Descrição das classes de cobertura de terra .....	51
Quadro 5 –	Principais características dos sensores utilizados no ano de 2020 .....	52
Figura 11 –	Índice NDVI do ano 2020 .....	59
Gráfico 2 –	Box plot do índice NDVI, ano 2020 .....	62
Figura 12 –	Índice SAVI do ano 2020 .....	64
Gráfico 3 –	<i>Box</i> plot do índice SAVI, ano 2020 .....	66
Figura 13 –	Índice EVI do ano 2020 .....	68
Gráfico 4 –	Box plot do índice EVI, ano 2020 .....	70
Figura 14 –	Índice VARIgreen do ano 2020 .....	72
Figura 15 –	Análise da sazonalidade da cobertura vegetal nas bordas da área de estudo a partir do índice VARIgreen .....	73
Gráfico 5 –	<i>Box</i> plot do índice VARIgreen, ano 2020 .....	75
Figura 16 –	Índice NDWI do ano 2020 .....	77

Gráfico 6 –	Box plot do índice NDWI, ano 2020 .....	79
Figura 17 –	Fragmento de vegetação em meio a solo exposto .....	81
Figura 18 –	Pequeno fragmento de solo exposto em meio a vegetação .....	82
Figura 19 –	Mapeamento da cobertura vegetal, ano 2020 .....	84
Figura 20 –	Concordância de mapeamento com o projeto MapBiomias 2020 .....	86
Quadro 6 –	Principais características do sensor utilizado .....	88
Figura 21 –	Espacialização dos valores dos índices NDVI, SAVI, EVI, VARIGreen e NDWI para o ano de 2000 .....	89
Gráfico 7 –	Box plot dos índices NDVI, SAVI, EVI, VARIGreen e NDWI, ano 2000 .....	92
Figura 22 –	Espacialização dos valores dos índices NDVI, SAVI, EVI, VARIGreen e NDWI para o ano de 2010 .....	94
Gráfico 8 –	<i>Box plots</i> dos índices NDVI, SAVI, EVI, VARIGreen e NDWI, ano 2010 .....	96
Figura 23 –	Mapeamento da cobertura vegetal, ano 2000 .....	97
Figura 24 –	Mapeamento da cobertura vegetal, ano 2010 .....	98
Figura 25 –	Concordância de mapeamento com o trabalho de Silva (2012) .....	99
Figura 26 –	Mapa de uso e ocupação da terra do estuário de Sirinhaém ano 2010	100
Figura 27 –	Mapeamento multitemporal da cobertura vegetal da área de estudo ....	103

## LISTA DE TABELAS

Tabela 1 –	Parâmetros de calibração CBERS-4 .....	41
Tabela 2 –	Parâmetros de calibração para o sensor MUX/CBERS-4A .....	42
Tabela 3 –	Dados estatísticos das imagens .....	54
Tabela 4 –	Diferenças entre os valores de médias .....	55
Tabela 5 –	Quantitativo de cobertura vegetal para o ano de 2020 .....	85
Tabela 6 –	Dados de concordância espacial da área de estudo com o projeto MapBiomias .....	87
Tabela 7 –	Dados de concordância espacial da área de estudo com o mapeamento de Silva (2012) .....	101

## LISTA DE ABREVIATURAS E SIGLAS

APA	Área de Proteção Ambiental
APAC	Agência Pernambucana de Águas e Climas
BOA	<i>Bottom of Atmosphere</i>
MLC	Classificação por Máxima Verossimilhança
DOS	<i>Dark Object Subtraction</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
EVI	<i>Enhanced Vegetation Index</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMBIO	Instituto Chico Mendes de Conservação da Biodiversidade
INPE	Instituto Nacional de Pesquisas Espaciais
LISS-3	<i>Linear Imaging Self Scanning</i>
SVM	Máquina de Vetores de Suporte
MSI	<i>Multispectral Instrument</i>
MUX	Câmera Multiespectral Regular
ND	Nível Digital
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized difference water index</i>
OLI	<i>Operational Land Imager</i>
PAN	Câmera Pancromática e Multiespectral
RF	<i>Random Forest</i>
SAVI	<i>Landsat Soil Adjusted Vegetation Index</i>
TM	Thematic Mapper
TOA	<i>Top of atmosphere</i>
USGS	<i>U.S. Geological Survey</i>
VARI	<i>Visual Atmospheric Resistance Index</i>
WFI	Câmera de Campo Largo
WPM	Câmera Multiespectral e Pancromática de Ampla Varredura

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
1.1	OBJETIVOS .....	18
1.2	ESTRUTURA DO TRABALHO .....	18
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>20</b>
2.1	MANGUEZAIS .....	20
2.2	DETECÇÃO DA COBERTURA VEGETAL DE MANGUE UTILIZANDO SENSORIAMENTO REMOTO .....	23
2.3	ÍNDICES DE VEGETAÇÃO .....	26
2.4	ESTUDOS DE VEGETAÇÃO DE MANGUE POR SENSORIAMENTO REMOTO .....	29
<b>3</b>	<b>MATERIAL E MÉTODOS .....</b>	<b>33</b>
3.1	ÁREA DE ESTUDO .....	33
3.2	METODOLOGIA .....	36
<b>3.2.1</b>	<b>Aquisição e processamento das imagens .....</b>	<b>37</b>
<b>3.2.2</b>	<b>Geração dos índices de vegetação .....</b>	<b>47</b>
<b>3.2.3</b>	<b>Análise dos Dados .....</b>	<b>50</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>52</b>
4.1	COMPARAÇÃO DE BANDAS ESPECTRAIS ENTRE OS SENSORES OLI, MSI, MUX, PAN E WPM .....	52
4.2	ANÁLISE DOS ÍNDICES DE VEGETAÇÃO .....	56
<b>4.2.1</b>	<b>NDVI – <i>Normalized Difference Vegetation Index</i> .....</b>	<b>57</b>
<b>4.2.2</b>	<b>SAVI – <i>Soil Adjusted Vegetation Index</i> .....</b>	<b>63</b>
<b>4.2.3</b>	<b>EVI - <i>Enhanced Vegetation Index</i> .....</b>	<b>67</b>
<b>4.2.4</b>	<b>VARIgreen – <i>Visible Atmospherically Resistance Index</i> .....</b>	<b>71</b>
<b>4.2.5</b>	<b>NDWI – <i>Normalized Difference Water Index</i> .....</b>	<b>76</b>
<b>4.2.6</b>	<b>Índices Fusionados .....</b>	<b>80</b>
4.3	MAPEAMENTO DA COBERTURA VEGETAL NO ANO 2020 .....	83
4.4	MAPEAMENTO DA COBERTURA VEGETAL NOS ANOS DE 2000 E 2010	88
<b>4.4.1</b>	<b>Análise dos índices .....</b>	<b>88</b>
4.5	ANÁLISE TEMPORAL DA COBERTURA VEGETAL .....	101

<b>5</b>	<b>CONCLUSÕES .....</b>	<b>105</b>
	<b>REFERÊNCIAS .....</b>	<b>107</b>

## 1 INTRODUÇÃO

Os manguezais desempenham um importante papel na dinâmica do ecossistema de áreas costeiras. São reconhecidamente a base da cadeia alimentar que sustenta essas áreas, alimentando espécies terrestres e marinhas. É berçário para inúmeras espécies de peixes e invertebrados. Também possuem um importante papel na ciclagem global de carbono e na redução da concentração do gás do efeito estufa atmosférico. Além de atuar no controle da erosão e proteção da costa de eventos extremos como tempestades, furacões e tsunamis. (ÁVILA-FLORES et al., 2020; CHAMBERLAIN; PHINN; POSSINGHAM, 2020; KANNIAH et al., 2015; PHAM et al., 2019; SHAPIRO et al., 2015; SILVA, 2012).

A importância desses ecossistemas vai além do aspecto ecológico. Para a comunidade local, fornecem recursos importantes tais como: matérias primas, plantas medicinais e alimentos. Possibilitam a subsistência de muitas famílias que vivem da pesca artesanal e da cata de moluscos e crustáceos. O caranguejo-uça, uma espécie endêmica do manguezal, tem grande importância socioeconômica, sobretudo no nordeste brasileiro, que detém a maior produção, servindo para o consumo interno em cidades turísticas da região litorânea (ÁVILA-FLORES et al., 2020; IVO; DIAS; MOTA, 1993; SILVA, 2012).

Mesmo frente a todas essas constatações, os manguezais são um dos mais ameaçados ecossistemas costais (KUENZER et al., 2011). A cobertura das florestas de manguezais vem diminuindo desde a década de 1980 (FAO, 2007; ICMBIO, 2018; SILVA, 2012). No mundo, cerca de 3,6 milhões de hectares de manguezais foram perdidos no período de 1980-2005, o que equivale a 20% da cobertura global de manguezais, segundo levantamento da FAO (FAO, 2007).

O Brasil é o segundo país no mundo em extensão de mangues, com aproximadamente 13.989 quilômetros quadrados. A maior porção está localizada na região norte, em três estados do bioma amazônico: Maranhão (36%), Pará (28%) e Amapá (16%). A região nordeste responde por cerca de 13,6% e o Estado de Pernambuco com cerca de 1,2% da área mapeada de mangue no Brasil. As estimativas do governo é de que 25% desse ecossistema já tenha sido perdido no país desde o início do século XX (ICMBIO, 2018). O levantamento mais recente, realizado por Diniz (et al. 2019) e disponibilizado pelo projeto MapBiomias – coleção 4.1, estima uma redução das áreas de florestas de mangues entre 2003 e 2017 de 2%.

Diante desse cenário, e considerando a relevância ecológica e econômica desse ecossistema costeiro, é imperativo implementar ações que contribuam para a sua conservação. Realizar ações de monitoramento com estimativas precisas das áreas perdidas e das mudanças

ocorridas nesse ecossistema são fundamentais para o desenvolvimento de estratégias que contribuam para o uso sustentável, a conservação e a redução da degradação e desmatamento (SHAPIRO et al., 2015). E nesse quesito, as geotecnologias têm sido utilizadas com sucesso em diversas iniciativas no Brasil e no mundo.

As imagens de satélites apresentam-se especialmente úteis para fornecer informações acerca das áreas de manguezais, visto que o acesso ao interior de densas florestas é extremamente difícil, além de consumir maior tempo e quantidade de recursos. Soma-se a este fato, a recente pandemia global causada pela Covid-19 e que restringiu ainda mais o acesso físico a essas áreas. O Sensoriamento remoto por outro lado, possui capacidade de imagear em curto espaço de tempo grandes porções da superfície terrestre e de maneira sistemática, possibilitando uma visão sinóptica (de conjunto) e multitemporal (em diferentes datas) das áreas, permitindo o monitoramento dessas florestas e das atividades antrópicas (MENESES; ALMEIDA, 2012; SANTOS et al., 2014).

O sensoriamento remoto apresenta-se como uma importante ferramenta para monitoramento dos manguezais e identificação de atributos como espécies, biomassa e avaliação de mudanças (PHAM et al., 2019; SANTOS; BITENCOURT, 2016). Dados de média resolução são amplamente utilizados para o mapeamento em larga escala de manguezais ao longo do tempo (SHAPIRO et al., 2015; WANG et al., 2018), enquanto que, dados de alta resolução são utilizados para validação, identificação de pequenas manchas de mangues e para a identificação da composição de espécies e causas das alterações nos manguezais (ARASATO et al., 2015; KUENZER et al., 2011). Dados hiperespectrais possuem aplicação na discriminação de várias espécies de manguezais (KANNIAH et al., 2015). E mais recentemente, o desenvolvimento de novas técnicas de *Machine Learning*, associadas a ambos os dados: ópticos e hiperespectrais, e também dados de Radar de Abertura Sintética (SAR), podem ser empregados para a classificação de espécies de manguezais (PHAM et al., 2019).

Ao longo dos anos, a evolução tecnológica e a disponibilidade de novos sensores com diferentes resoluções espaciais, espectrais e radiométricas, abriu espaço para estudos que os utilizem de maneira conjunta, buscando a complementaridade. A abordagem multisensor pode representar vantagens por conta da maior quantidade de imagens disponíveis num mesmo período de interesse e que podem contribuir para aquisição de imagens livres de nuvens e/ou compatibilização de datas de aquisição mais próximas, dois aspectos importantes em estudos multitemporais (BENDINI et al., 2017; BEZERRA, 2019; MOUSIVAND et al., 2015). Avaliar essa possibilidade em sistemas com cobertura global e acesso livre e aberto, como os dados

Landsat, CBERS e Sentinel-2, é um aspecto adicional que vem contribuir com a comunidade usuária desses dados.

As imagens da série Landsat são os produtos mais utilizados como fonte de dados em uma infinidade de diferentes tipos de estudos (MARTINS; BORGES, 2020) e oferecem uma cobertura temporal ininterrupta ao longo de quase 50 anos, desde o lançamento do primeiro satélite, Landsat-1, em 1972. O Copernicus Sentinel-2 é o programa de imageamento europeu para monitoramento terrestre lançado em 2015. O acesso aos dados Landsat e Sentinel-2 pode ser feito livremente a partir do site USGS *Earth Explorer* em <https://earthexplorer.usgs.gov/>.

O programa Satélite Sino-Brasileiro de Recursos Terrestres (CBERS) é fruto de cooperação técnico-científica entre o Brasil e China que já resultou na construção e lançamento de seis satélites de sensoriamento remoto. O primeiro foi lançado em outubro de 1999 e o mais recente, CBERS-4A, em dezembro de 2019. Os dados estão disponíveis no site do Instituto Nacional de Pesquisas Espaciais (INPE) (<http://www2.dgi.inpe.br/catalogo/explore>).

Trabalhos científicos utilizando dados CBERS em conjunto com dados de outros programas ainda são escassos na literatura nacional e internacional. Desse modo, estudos comparativos utilizando índices de vegetação e dados multiespectrais em diferentes datas, com imagens Landsat (TM e OLI), CBERS (MUX, PAN e WPM) e Sentinel-2 (MSI), ainda não foram reportados no ambiente manguezal e desponta como um desafio com potencial para importantes esclarecimentos em relação a complementaridade desses dados e a sensibilidade dos produtos gerados para a detecção e monitoramento de cobertura vegetal de mangue.

Além disso, a área selecionada para este estudo, o estuário do Rio Sirinhaém, localizada no litoral sul do Estado de Pernambuco, numa região entre dois polos de desenvolvimento: o Porto de Suape e o turismo de Porto de Galinhas ao norte e o turismo da Praia dos Carneiros e Tamandaré, ao sul, é uma das três áreas onde houve diminuição das florestas de mangue no período de 1987 a 2010, conforme dado revelado por mapeamento realizado em 11 áreas de estuário do Estado (SILVA, 2012).

Frente ao exposto, a pesquisa ora apresentada pretende contribuir realizando estudos sobre a utilização de produtos de sensoriamento remoto multifonte e multiespectral na discriminação do dossel de cobertura vegetal de mangue para o mapeamento e detecção de mudanças nessa cobertura ao longo dos anos de 2000 a 2020. Esta iniciativa faz parte do projeto de pesquisa “Análise Multifonte de Imagens de Sensoriamento Remoto”, processo número 23076.052607/2017-43 (2017-2021), vinculado ao Laboratório de Sensoriamento Remoto e Processamento de Imagens do Departamento de Engenharia Cartográfica (CTG) da Universidade Federal de Pernambuco – UFPE.

## 1.1 OBJETIVOS

### Objetivo Geral

Realizar análise temporal (anos 2000 a 2020) multifonte (Landsat, CBERS e Sentinel-2) da cobertura vegetal do estuário do Rio Sirinhaém, litoral sul do Estado de Pernambuco.

### Objetivos Específicos

- a) Analisar a sensibilidade multiespectral de índices físicos entre diferentes sistemas sensores da cobertura vegetal do Estuário do Rio Sirinhaém no ano 2020;
- b) Quantificar as transformações espaciais ocorridas ao longo da série histórica (anos 2000, 2010 e 2020) da cobertura vegetal do Estuário do Rio Sirinhaém;
- c) Analisar espacialmente, espectralmente, e estatisticamente as bordas da cobertura vegetal do Estuário do Rio Sirinhaém entre os meses de setembro a dezembro do ano 2020.

## 1.2 ESTRUTURA DO TRABALHO

Esta dissertação está dividida em seis itens, enumerados e resumidos a seguir:

O capítulo 1: **Introdução**, traz uma apresentação geral sobre o tema, a justificativa para a elaboração desse trabalho e da escolha do local de estudo, bem como os objetivos e a estrutura do trabalho.

O capítulo 2: **Referencial Teórico**, procuramos atender a necessidade de revisão bibliográfica de base teórica referente a detecção da cobertura vegetal de mangue utilizando sensoriamento remoto orbital, incluindo o uso de Índices de vegetação e um apanhado dos trabalhos publicados no Brasil e no mundo acerca da utilização do Sensoriamento Remoto no estudo de mangue.

O capítulo 3: **Material e Métodos**, apresentamos inicialmente a área de estudo no item 3.1 e posteriormente, no item 3.2, tratamos dos passos metodológicos que foram empreendidos para a execução dessa pesquisa.

O capítulo 4: **Resultados e Discussões** apresentamos todos os resultados obtidos neste trabalho, analisando e discutindo.

No capítulo 5: **Conclusões**, seguem as principais conclusões e avaliações dos resultados obtidos, além de recomendações para estudos futuros que abordem o tema.

O último capítulo: **Referências**, enumeramos todos os trabalhos utilizados diretamente por esta pesquisa.

## 2 REFERENCIAL TEÓRICO

### 2.1 MANGUEZAIS

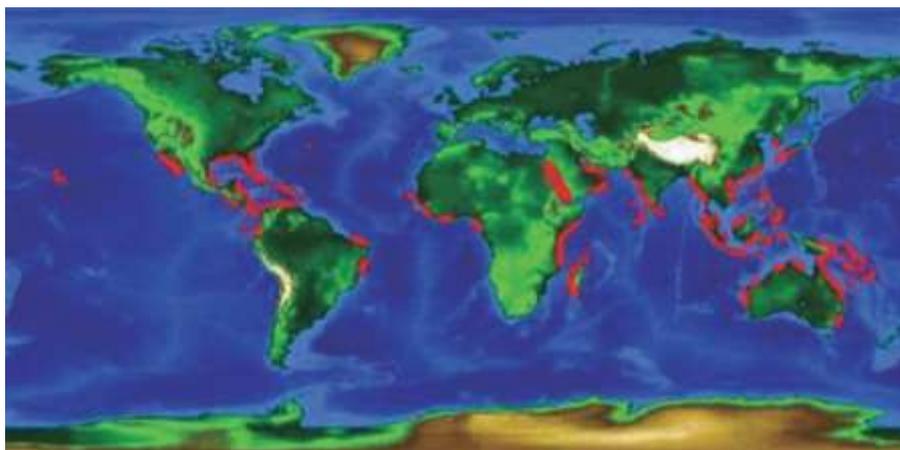
Os manguezais são ecossistemas relevantes do ponto de vista ecológico e também socioeconômico. Estão inseridos entre as Zonas Úmidas definidas pela Convenção de Ramsar, da qual o Brasil é signatário, reconhecendo-as como recurso de grande valor social, econômico, cultural, científico e recreativo e cuja perda seria irreparável (MMA, 2022).

Podem ser definidos como sendo:

*“um ecossistema costeiro, de transição entre os ambientes terrestre e marinho, característico de regiões tropicais e subtropicais, sujeito ao regime das marés e constituído de espécies vegetais lenhosas típicas (angiospermas), além de micro e macroalgas (criptógamas) adaptadas à flutuação da salinidade, sedimentos predominantemente lodosos e com baixos teores de oxigênio. Ocorre em áreas costeiras abrigadas e apresenta condições propícias para alimentação, proteção e reprodução de muitas espécies animais”* (Schaeffer-Novelli, 1995 *apud* FRUEHAUF, 2005, pág. 1).

Os manguezais estão restritos a zona intertropical terrestre entre as latitudes 30° Norte e Sul, podendo variar a dispersão para maiores ou menores latitudes a depender da temperatura da água do mar limitada pela isoterma de 20° C (ver Figura 1). No mundo, estima-se uma área total de cobertura de manguezais entre 167.000 e 181.000 km<sup>2</sup>. A maior quantidade pode ser encontrada no sudeste da Ásia, onde eles são melhores desenvolvidos e possuem maior diversidade de espécies (KUENZER et al., 2011).

Figura 1 – Distribuição dos manguezais no mundo



Fonte: Rosati (et al., 2008).

O Brasil é o segundo país no mundo em extensão de mangues, com aproximadamente 13.989 quilômetros quadrados. A maior porção está localizada na região norte, em três estados do bioma amazônico: Maranhão (36%), Pará (28%) e Amapá (16%). A região nordeste responde por cerca de 13,6% e o Estado de Pernambuco com cerca de 1,2% da área mapeada de mangue no Brasil (ICMBIO, 2018).

No litoral nordestino, os manguezais são mais baixos e estruturalmente menos complexos que os do litoral norte e estão restritos à área de influência das marés ao longo dos estuários dos principais rios da região. Sua penetração no continente é condicionada pela penetração das águas salinas, que impedem a colonização das margens dos rios por matas ciliares e outros tipos de vegetação que não suportam teores elevados de sal. No limite que vai do estado do Piauí a Pernambuco, a extensão dos manguezais é de aproximadamente 600 quilômetros quadrados (MENEZES, 2006).

Os manguezais participam da dinâmica geoambiental nos ambientes litorâneos cuja evolução depende dos fluxos de matéria e energia associados aos processos hidrodinâmicos derivados das oscilações de marés. Dessa forma, a constante influência marinha junto a margens com sedimento lamoso e águas abrigadas e salobras são fatores condicionantes que permitem o surgimento de uma vegetação típica de áreas estuarinas, denominada manguezal. A espécie mais difundida ao longo da costa brasileira é o mangue vermelho (*Rhizophora mangle*), com raízes escoras que se ramificam dentro da lama. Também encontramos o mangue preto (*Avicennia racemosa*), com raízes respiratórias, destinadas a compensar a falta de oxigênio do substrato, e o mangue branco (*Laguncuraria racemosa*), que tolera mal as inundações e prefere solos mais firmes (AMBITEC, 2008; FRUEHAUF, 2005; MAIA et al., 2005; SILVA, 2012). Em relação a fauna, o número de espécies encontradas nessas áreas é muito variado, indo desde

formas microscópicas até grandes peixes, aves, répteis e mamíferos, que ocupam o sedimento, a água, as raízes, troncos e copas das árvores.

Em relação a sua importância ecológica, considera-se que os manguezais se comportam como uma barreira natural contra a dinâmica dos oceanos ao longo da costa, protegendo contra desastres naturais tais como: furacões, ciclones, tsunamis, e ajudando a prevenir o processo de erosão costeira, quebrando a força das ondas. Os ecossistemas de mangue sustentam a cadeia alimentar aquática e formam habitats para a fauna marinha de caranguejos juvenis, camarões, peixes e larvas. Manguezais também são capazes de manter a qualidade da água atuando como filtros biológicos, separando sedimentos e nutrientes em áreas costeiras poluídas. Além de tudo isso, manguezais são importantes para o balanço de carbono da zona costeira (FRUEHAUF, 2005; KUENZER et al., 2011).

Além da sua importância ecológica acima mencionada, ressalta-se a socioeconômica tendo em vista as inúmeras comunidades que praticam a pesca artesanal e de subsistência. São pescadores e catadores de crustáceos e moluscos que dependem desse ambiente para tirarem seu sustento. Soma-se a isto as atividades de turismo e lazer (passeios, visitaç o, contemplaç o) e atividades de educaç o ambiental e pesquisas cient ficas.

Mesmo assim, apesar de sua import ncia, os manguezais no Brasil s o vulner veis a uma s rie de ameaças, tais como perda e fragmenta o de cobertura vegetal, a deteriora o da qualidade de habitats aqu ticos, devido sobretudo   ocupa o,   polui o e  s mudanças na hidrodin mica, o que tem promovido a diminui o na oferta de recursos dos quais muitas comunidades tradicionais e setores dependem diretamente para sobreviver (ICMBIO, 2018).

As zonas costeiras, al m de sofrerem a variabilidade induzida por mudanças globais,   hoje a regi o de maior densidade populacional do planeta e hospeda grande partes das  reas urbanas e regi es industriais (MENEZES, 2006). Dessa forma, atividades antr picas relacionadas a estas ocupa es, tais como: represamento de rios, instala es de  reas de lazer, turismo e urbaniza o; obras de engenharia marinha (portos, canais naveg veis, dragagens e aterros), dentre outras interven es, resultam em mudanças r pidas das caracter sticas ambientais locais.

Por esse motivo, h  a real necessidade de se implementar a es que visem sua conserva o, pois a degrada o desse ecossistema resulta em perdas econ micas, sociais e ecol gicas.

## 2.2 DETECÇÃO DA COBERTURA VEGETAL DE MANGUE UTILIZANDO SENSORIAMENTO REMOTO

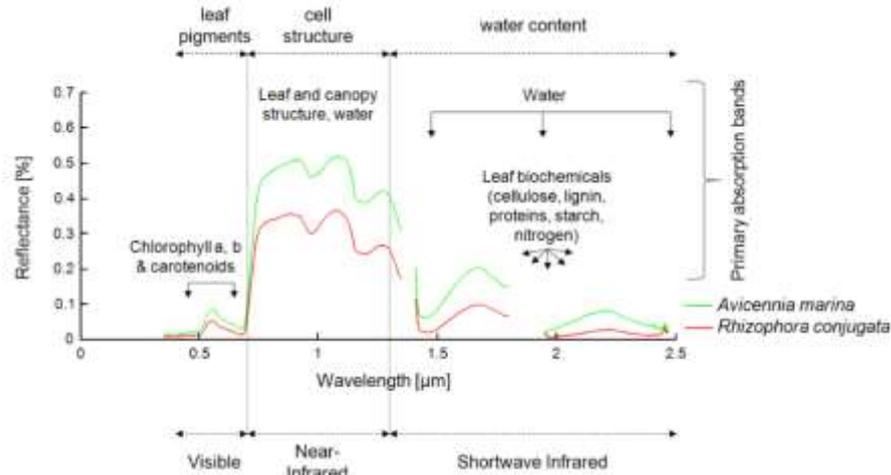
O Sensoriamento Remoto oferece múltiplos benefícios ao ser aplicado em estudos que envolvem manguezais. Devido a suas características de localização geográfica e aspectos físicos, esses ecossistemas oferecem grande dificuldade de acesso e nesses casos, amostragens de campo tornam-se excessivamente caras e lentas. Por esse motivo, imagens de satélites são frequentemente utilizadas para o mapeamento, classificação, avaliação e determinação da composição de espécies (WANG et al., 2016). Também para determinação do status de conservação e detecção de alterações no ecossistema (KANNIAH et al., 2015).

Kuenzer (et al. 2011) destaca que o sensoriamento remoto de manguezais oferece informações importantes para: Inventários (determinação da extensão, espécies e composições, status de conservação); Detecção de mudanças e monitoramento; Avaliação da produtividade (estimativas de biomassa); Estimativas da capacidade de regeneração; Avaliação da qualidade de água; Planejamento para trabalhos de campo; dentre outros.

Os manguezais estão localizados na interface terra-mar e os três principais alvos que contribuem para a composição do pixel em imagens de Sensoriamento Remoto são a vegetação, solo e água (KUENZER et al., 2011). Por esse motivo, é importante realizar um breve estudo dos principais aspectos relativos à interação da radiação eletromagnética com esses alvos.

Tendo em conta a vegetação, as folhas, dentre todas as partes das plantas, são as que mais contribuem no processo de interação com a radiação eletromagnética. Na fotossíntese, processo fundamentado na absorção da radiação eletromagnética por parte dos pigmentos fotossintetizantes presentes nas folhas, o vegetal é capaz de produzir a energia de que necessita para viver e crescer. Os principais pigmentos fotossintetizantes encontrados principalmente nas folhas são: clorofila, carotenos e xantofilas. Destes, a absorção da clorofila é a mais destacada. Entretanto, a absorção da radiação por esses pigmentos se dá apenas na faixa do visível, compreendendo os comprimentos de onda entre 0,4  $\mu\text{m}$  e 0,72  $\mu\text{m}$  (MOREIRA, 2011; PONZONI; SHIMABUKURO; KUPLICH, 2012). Esse comportamento explica o primeiro intervalo espectral, do visível, mostrado na Figura 2, que apresenta a curva espectral típica de uma folha verde e a alta taxa de absorção da REM nessa faixa espectral.

Figura 2 – Curva espectral típica de uma folha verde



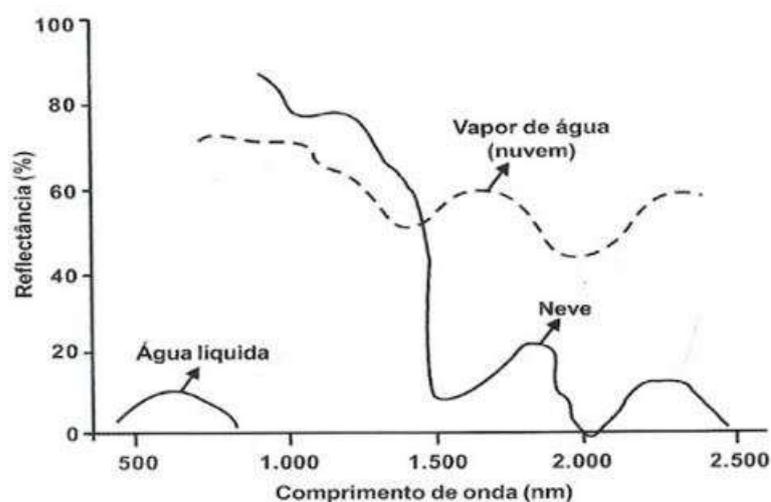
Fonte: KUENZER et al., 2011

O segundo intervalo na curva refere-se a região espectral do infravermelho próximo (0,72  $\mu\text{m}$  – 1,1  $\mu\text{m}$ ). Nessa região ocorre absorção pequena e considerável espalhamento da radiação em virtude das estruturas internas presentes nas folhas, tais como: número de camadas celulares, espaços intercelulares, tamanho das células e outros (KUENZER et al., 2011; MOREIRA, 2011; PONZONI; SHIMABUKURO; KUPLICH, 2012).

Por fim, o terceiro intervalo na curva espectral refere-se a região do infravermelho médio, compreendido entre 1,1  $\mu\text{m}$  e 3,2  $\mu\text{m}$ . Nessa região espectral, a característica marcante é a absorção da radiação em virtude do conteúdo de água presente nas folhas. O pico de absorção nessa faixa se dá 1,4  $\mu\text{m}$  e 1,95  $\mu\text{m}$  (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Já em relação ao alvo água (no estado líquido da matéria), seu comportamento espectral é marcado pelas altas taxas de absorção da radiação eletromagnética incidente em quase todas as faixas do espectro eletromagnético. Há pequena refletância, pouco mais de 5%, apenas na faixa entre 0,38  $\mu\text{m}$  e 0,7  $\mu\text{m}$  (MOREIRA, 2011) (Figura 3). Nesse sentido, existe uma relação inversa entre a quantidade de água presente na folha e a radiação que é refletida, ou seja, quanto maior o teor de umidade no interior das folhas, menor é a quantidade de radiação refletida nas faixas espectrais do infravermelho próximo e infravermelho médio (MOREIRA, 2011; PONZONI; SHIMABUKURO; KUPLICH, 2012).

Figura 3 – Curva espectral da água nos estados líquido, gasoso (nuvem) e sólido (neve)



Fonte: Moreira, 2011.

A resposta espectral do solo depende diretamente de sua composição química (teor de pH, óxidos de ferro, etc), aspectos biológicos (teor de matéria orgânica), granulométricas (tamanho das partículas), e outros aspectos, tais como: a rugosidade da superfície e o teor de umidade. Com base na reflectância espectral desses parâmetros podemos observar a “aparência” dos solos nas imagens. Por exemplo, um solo rico em óxido de ferro e de minerais opacos tem afetado seu comportamento espectral, diminuindo sua reflectância. A quantidade de umidade retida no solo tem relação com a sua textura, também relacionada com o tamanho das partículas, quanto mais fina a textura, maior a capacidade de reter umidade e consequentemente, maior será a absorção da radiação eletromagnética incidente na região do visível e infravermelho. Temos ainda que, a quantidade de matéria orgânica no solo também pode influenciar seu comportamento espectral: à medida que o teor de matéria orgânica aumenta, a reflectância do solo decresce no intervalo de comprimento de onda de 400 a 2.500 nm. (HIPÓLITO, 2017; JENSEN, 2009; MOREIRA, 2011; SILVA, 2012).

Quando observados com produtos de sensoriamento remoto óptico, as principais características usadas para identificar as florestas de manguezais são os atributos espectrais e de textura das folhas e dossel. Desse modo, a aparência na imagem poderá resultar num padrão mais homogêneo ou heterogêneo, a depender de muitas variáveis tais como: composição de espécies, distribuição, forma e densidade de crescimento e o padrão de altura (KUENZER et al., 2011). Outros fatores envolvidos são fisiológicos tais como: idade da planta e conteúdo de água nas folhas (MOREIRA, 2011).

O regime característico das marés no ambiente dos manguezais e o tipo de solo também podem influenciar na resposta espectral, de modo que uma vegetação com menor densidade de cobertura pode sofrer maior influência da reflectância da superfície abaixo do dossel (efeito *background*). Isso pode resultar em maior radiação refletida no caso de um solo arenoso ou o oposto, no caso de um solo encharcado, por exemplo. Outro ponto é com relação as mudanças climáticas das estações do ano que podem influenciar a dinâmica foliar e conseqüentemente, alterar a resposta espectral (KUENZER et al., 2011).

### 2.3 ÍNDICES DE VEGETAÇÃO

O sensoriamento remoto possui a capacidade, dada sua natureza de funcionamento, de coletar dados primários que podem ser convertidos, a partir de um processamento adequado, em informação útil para o entendimento de processos relacionados a uma determinada aplicação. Técnicas de processamento digital de imagens possibilitam a obtenção de índices de vegetação, que são úteis em diversas aplicações tais como: examinar propriedades espectrais da vegetação, caracterizar, quantificar e determinar parâmetros biofísicos de culturas agrícolas e florestas naturais, discriminação entre vegetação nativa e áreas de cultivo, dentre outras (ANJOS, 2017; MOREIRA, 2011).

Índices de vegetação podem ser considerados como sendo medidas radiométricas adimensionais geradas a partir de fórmulas matemáticas que utilizam dados multiespectrais dos sensores remotos (PONZONI; SHIMABUKURO; KUPLICH, 2012).

O emprego de índices de vegetação permite realçar a componente espectral da vegetação, diferenciando-a em meio aos demais alvos. Também consegue reduzir a dimensão das informações multiespectrais, minimizar o impacto das condições de iluminação da cena, declividade da superfície e geometria da aquisição, além de fornecer dados fortemente correlacionados a parâmetros biofísicos da cobertura vegetal, tais como biomassa e índice de área foliar (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Diversos índices de vegetação foram propostos ao longo do tempo. Alguns são funcionalmente equivalentes (redundantes) em termos de conteúdos de informação e outros provem informações singulares (JENSEN, 2009). O princípio de funcionamento deles reside no comportamento antagônico da reflectância da vegetação em duas regiões espectrais, principalmente, nas faixas do visível e do infravermelho próximo. Em síntese, quanto maior for a densidade da cobertura vegetal em uma determinada área, menor será a reflectância na região do visível, em razão da maior oferta de pigmentos fotossintetizantes. Por outro lado, maior será

a reflectância na região do infravermelho próximo, em virtude do espalhamento múltiplo da radiação nas diferentes camadas de folhas (JENSEN, 2009; PONZONI; SHIMABUKURO; KUPLICH, 2012).

São inúmeros os trabalhos que aplicam índices de vegetação em estudos de monitoramento de manguezais (ARASATO et al., 2015; ÁVILA-FLORES et al., 2020; CASTILLO et al., 2017; DINIZ et al., 2019; MELO, 2017; SILVA, 2012; VALDERRAMA-LANDEROS et al., 2018; WANG et al., 2018). Um dos índices mais amplamente utilizados é o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index – NDVI*), proposto por Rouse (*et al.*, 1974) com a finalidade de quantificar o crescimento e a biomassa acumulada da vegetação. O NDVI é calculado a partir da Equação 1 abaixo:

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

Onde:

NIR = reflectância no infravermelho próximo

RED = reflectância no vermelho

O NDVI possui como principais características: minimizar os efeitos da topografia; pode saturar em regiões de vegetação densa; é sensível aos efeitos de brilho do solo, cor do solo, atmosfera, sombra de nuvem e sombra de dossel (JENSEN, 2009; PONZONI; SHIMABUKURO; KUPLICH, 2012).

O Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index - SAVI*) introduziu uma constante “L” ao NDVI que tem a função de minimizar o efeito do solo no resultado final do índice melhorando o desempenho principalmente em áreas com baixo teor de cobertura vegetal, ou seja, com a presença natural de exposições de solo (MENESES; ALMEIDA, 2012). Essa constante varia entre 1 (vegetação rala) e 0 (vegetação densa). O índice SAVI pode ser calculado a partir da Equação 2:

$$SAVI = \frac{(1 + L) * (NIR - RED)}{NIR + RED + L} \quad (2)$$

Onde:

L = constante que minimiza o efeito do solo e pode variar entre 0 e 1.

O Índice de Vegetação Melhorado (*Enhanced Vegetation Index – EVI*) foi desenvolvido para otimizar o sinal da vegetação, melhorando a sensibilidade de sua detecção em regiões com maiores densidades de biomassa. Também é capaz de reduzir a influência do solo e da atmosfera na resposta do dossel, além de apresentar alta resposta a variações fenológicas (ALMEIDA et al., 2008). Esse índice é calculado a partir da Equação 3 a seguir:

$$EVI = G * \frac{(NIR - RED)}{L + NIR + C_1 * RED - C_2 * BLUE} \quad (3)$$

Onde:

G = Fator de ganho; valor adotado = 2,5

L = Fator de ajuste para o solo; valor adotado = 1

C1 e C2 = Coeficientes de ajuste de aerossóis da atmosfera; valores adotados C1 = 6; C2 = 7,5

BLUE = reflectância no azul

Em relação ao Índice de Água por Diferença Normalizada (*Normalized Difference Water Index - NDWI*) é conhecido na literatura duas variações. O índice proposto por MCFEETERS (1996) e o índice proposto por GAO (1996) (ver Equações 4 e 5). Apesar de utilizarem a mesma terminologia, os índices possuem propostas diferentes. O índice NDWI de McFeeters utiliza as faixas espectrais do verde e do infravermelho próximo e objetiva dar destaque ao delineamento de feições hídricas do terreno. Já o índice NDWI de Gao, substitui a faixa espectral do visível por uma banda da faixa do infravermelho médio (SWIR) e tem maior propósito de realçar o conteúdo de água líquida presente na vegetação (PEREIRA et al., 2018). No nosso estudo, tendo em conta que os sensores CBERS não possuem bandas na faixa espectral do infravermelho médio, optamos por utilizar a metodologia de McFeeters. Segundo Pereira (*et al.*, 2018), a aplicação desse índice em áreas úmidas continentais (por exemplo, pantanal), nos propicia ótima diferenciação entre corpos hídricos e vegetação arbórea, mas apresentará maior confusão espectral para os alvos de solo úmido, solo exposto e vegetação rasteira.

$$NDWI_{McFeeters} = \frac{GREEN - NIR}{GREEN + NIR} \quad (4)$$

$$NDWI_{Gao} = \frac{NIR - SWIR}{NIR + SWIR} \quad (5)$$

O Índice de Vegetação Resistente à Atmosfera na Região do Verde (*Visible Atmospherically Resistant Index - VARIgreen*) foi um índice proposto por Gitelson (*et al.*, 2002) e utiliza apenas o espectro do visível para estimar e quantificar a fração de vegetação no dossel (em termos de proporção desse componente no pixel). Esse índice é resistente aos ruídos atmosféricos em virtude da utilização da banda do azul nos cálculos e pode ser obtido a partir da Equação 6:

$$VARI_{GREEN} = \frac{GREEN - RED}{GREEN + RED - BLUE} \quad (6)$$

#### 2.4 ESTUDOS DE VEGETAÇÃO DE MANGUE POR SENSORIAMENTO REMOTO

O monitoramento dos manguezais por meio da análise de imagens de satélite vem sendo realizado a nível global desde a década de 1980 (DINIZ *et al.*, 2019). Inúmeros estudos em temáticas diversas têm sido realizados ao longo dos últimos anos. Para avaliar e determinar mudanças ocorridas em florestas de manguezais em séries históricas (ÁVILA-FLORES *et al.*, 2020; CHAMBERLAIN; PHINN; POSSINGHAM, 2020; DINIZ *et al.*, 2019; KANNIAH *et al.*, 2015; MELO, 2017; SHAPIRO *et al.*, 2015; SILVA, 2012). Para identificação de espécies vegetais de manguezais como em: (VALDERRAMA-LANDEROS *et al.*, 2018; WANG *et al.*, 2016). Para estimativas de biomassa e outros parâmetros biofísicos e determinação de estoques de carbono (KAMAL; PHINN; JOHANSEN, 2014; MELO, 2017; PASTOR-GUZMAN *et al.*, 2015; SHAPIRO *et al.*, 2015) dentre outros.

No Brasil, o primeiro mapeamento nacional de manguezais foi realizado por Herz e publicado em 1991. Foi baseado em imagens de sensoriamento remoto disponíveis do ano de 1978 e a área de cobertura encontrada foi de 10.123,76 km<sup>2</sup> (MAIA *et al.*, 2005). Posteriormente, Kjerfve e Lacerda (1993 *apud* MAIA *et al.*, 2005), estimaram uma cobertura com área de 13.800 km<sup>2</sup>. Em 2010, um novo mapeamento dos manguezais em escala nacional utilizando imagens Landsat 5 do ano 2009 estimou a área de cobertura em 11.143 km<sup>2</sup>

(MAGRIS; BARRETO, 2010). Em 2018, o Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) publicou o “Atlas dos Manguezais do Brasil” e estimou a área total de cobertura no país em 13.989 km<sup>2</sup> a partir de imagens Landsat 8, sensor OLI (ICMBIO, 2018). O levantamento mais recente a nível nacional foi o elaborado por Diniz (et al., 2019) e publicado pelo projeto MapBiomias – coleção 4.1, que estimou a área total ocupada por manguezais no Brasil em 9.940 km<sup>2</sup>.

Atualmente, existe um grande número de sistemas sensores de média-resolução e dados livres que podem ser utilizados para estudos de manguezais, tais como: ETM+ (Enhanced Thematic Mapper Plus) e OLI (Operational Land Imager) dos satélites Landsat; MUX (Câmera Multiespectral Regular), PAN (Câmera Pancromática e Multiespectral), WFI (Câmera de Campo Largo) e WPM (Câmera Multiespectral e Pancromática de Ampla Varredura) dos satélites CBERS; MSI (*MultiSpectral Instrument*) do Sentinel-2; LISS-3 (Linear Imaging Self Scanning) do Resourcesat-2 e outros. Imagens em média-resolução (entre 5 e 80 metros de resolução espacial) são excelentes para mapeamento de ecossistemas, monitoramento de mudanças em larga escala, análises de relações ambientais regionais e avaliações das condições de manguezais (vigor vegetativo, idade, densidade, dentre outros) (KUENZER et al., 2011; SANTOS; BITENCOURT, 2016).

As imagens da série Landsat são os produtos mais utilizados como fonte de dados em uma infinidade de diferentes tipos de estudos (MARTINS; BORGES, 2020). Oferecem uma cobertura temporal ininterrupta ao longo de quase 50 anos e já foram amplamente testadas em inúmeros estudos. Shapiro (et al. 2015) utilizou imagens Landsat de 1994, 2000 e 2013 para avaliar e determinar as mudanças ocorridas no manguezal do Delta do Rio Zambezi em Moçambique, com intuito de determinar os efeitos das mudanças nos estoques de carbono. O estudo conseguiu detectar um incremento na cobertura vegetal de 3.723 hectares em 2013 quando comparado com o ano de 1994, além de mapear as áreas onde houve incremento e perda de vegetação de mangue na área de estudo. Kanniah (*et al.*, 2015) analisou as mudanças ocorridas ao longo de 25 anos em áreas de manguezais em Iskandar Malaysia, uma região de rápido crescimento econômico no sul da Malásia peninsular. Os autores utilizaram imagens Landsat e testaram duas diferentes técnicas de classificação digital de imagens: classificação por máxima verossimilhança (MLC) e Máquina de Vetores de Suporte (SVM), sendo que o método de máxima verossimilhança produziu os melhores resultados. O estudo apontou para uma perda de 6.030 hectares de manguezais no período de 1989 a 2014, com taxa anual de perda de cerca de 241 hectares por ano. Chamberlain, Phinn, and Possingham (2020), investigaram as mudanças e tendências numa grande área de estuário em Central Queensland,

Austrália ao longo de uma série temporal 2004-2017 utilizando dados Landsat. Nove classes de informação foram compiladas a partir da classificação digital das imagens pelo método de máximo verossimilhança e basearam extensa análise acerca das mudanças no arranjo da cobertura do solo na área de estudo e no período da pesquisa. As classes *Mangroves*, *estuarine wetland* e *saltmarsh grass* diminuíram cerca de 1.146, 1.495 e 1.628 hectares, respectivamente, em detrimento de áreas de pastagens (CHAMBERLAIN; PHINN; POSSINGHAM, 2020).

No Estado de Pernambuco, Silva (2012), realizou o mapeamento da vegetação de mangue em onze áreas estuárias do Estado, utilizando imagens TM do Landsat 5 obtidas entre os anos de 1987 a 2010. A partir dos resultados, a autora contabilizou um acréscimo de 9,1 km<sup>2</sup> nas áreas de manguezais, que foi associado à expansão das áreas de inundação pelas águas de marés, suscitando um aumento relativo do nível do mar. Por outro lado, em três estuários da pesquisa houve diminuição de área, incluindo aí o estuário do Rio Sirinhaém, selecionado para este estudo. Para a autora, as reduções de vegetação de mangue ocorreram em detrimento da expansão de núcleos urbanos, desmatamento e instalação de fazendas de camarão (SILVA, 2012).

No cenário mais atual, o Sentinel-2, fornecendo imagens gratuitamente em alta resolução temporal e boa resolução espacial e espectral, inclusive com as bandas na faixa *red-edge*, também vem sendo empregado para o mapeamento, monitoramento e mudanças na cobertura, como em: (CASTILLO et al., 2017; GUARIGLIA PEREZ, 2018; VALDERRAMA-LANDEROS et al., 2018). Também é possível encontrar trabalhos em que dados Landsat e Sentinel-2 são utilizados de forma conjunta e comparados entre si. Valderrama-Landeros (*et al.*, 2018), avaliaram a acurácia da classificação de florestas de manguezais usando diferentes dados de sensoriamento remoto, incluindo imagens Landsat-8, SPOT-5, WorldView-2 e Sentinel-2. Os resultados mostraram que a menor acurácia na classificação foi com dados Landsat-8 (30 m cada pixel) e a maior com dados WorldView-2 (1,6 m cada pixel). Enquanto que SPOT-5 e Sentinel-2 tiveram resultados similares. Os autores concluíram que dentre os vários tipos de sensores utilizados, os de alta resolução espacial podem ser particularmente importantes para o mapeamento de pequenas áreas de manguezais.

Em menor escala, dados do CBERS também têm sido utilizados em diferentes temas relacionados a recursos terrestres, incluindo a classificação e monitoramento de cultivos agrícolas, avaliação de recursos terrestres, monitoramento de riscos geológicos e para a investigação e monitoramento de ecossistemas (MARTINS; BORGES, 2020). Liu (*et al.*, 2019), avaliaram o potencial do uso de imagens CBERS-4 (5 metros de resolução espacial) para o mapeamento de pequenas manchas de vegetação quase circulares no Delta do Rio Yellow,

China, utilizando classificação pelo método *Random Forest* (RF). A classificação foi operacionalizada usando imagens individuais e também imagens combinadas de mais de um período do ano, afim de detectar a melhor abordagem em relação ao efeito de sazonalidade (condição da vegetação frente às estações do ano) e a importância do período de aquisição das imagens para o mapeamento. Para a classificação baseada na imagem individual, o período do início da primavera (em março) alcançou a melhor acurácia geral de mapeamento (98,1%). Neves e Mucida (2020) utilizaram índices espectrais (NDVI e SAVI) para comparar a representação da vegetação em uma área de cerrado brasileiro a partir dos dados CBERS-4, Landsat-8 e Rapideye e constataram que os dados CBERS apresentaram resultado de NDVI semelhantes ao Rapideye, mesmo com resolução espacial mais baixa. Os resultados NDVI e SAVI do Landsat-8 mostraram valores discrepantes quando comparados aos dados CBERS e Rapideye. Além disso, os autores detectaram um erro na geração do índice SAVI com dados CBERS-4 e o relacionaram ao valor da constante “L” desse índice, incapaz de retratar a variação da vegetação nessa área estudada.

### 3 MATERIAL E MÉTODOS

#### 3.1 ÁREA DE ESTUDO

A área compreendida neste estudo é o estuário do rio Sirinhaém, localizado na porção sul do litoral do estado de Pernambuco, entre os municípios de Ipojuca e Sirinhaém. Essa é uma região que se situa entre dois polos de desenvolvimento do Estado, ao norte: o Porto de Suape e o turismo de Porto de Galinhas e ao sul: o turismo da Praia dos Carneiros e Tamandaré (Ver Figura 4).

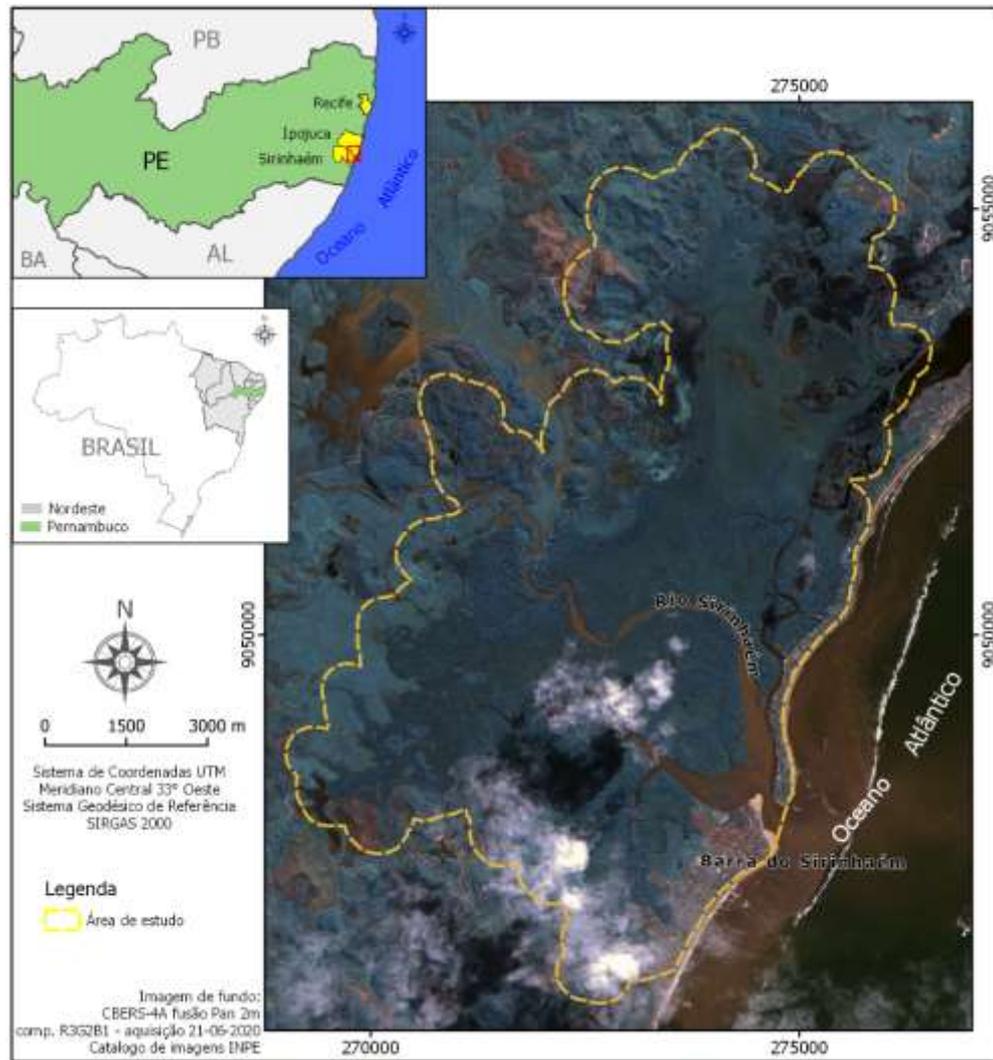
O município de Ipojuca faz parte da Região Intermediária de Recife e da Região Imediata de Recife, conforme a mais recente divisão regional do Brasil divulgado pelo IBGE (IBGE, 2017). Sua sede está localizada à cerca de 50 quilômetros de Recife, e possui altitude de 10 metros. Sua área é de 521,8 quilômetros quadrados e população estimada em 2021 era de 99.101 habitantes (IBGE, 2021). É um importante município na economia do Estado, apresentando o maior Produto Interno Bruto (PIB) per capita de Pernambuco (IBGE, 2019). Limita-se ao norte pelo município de Cabo de Santo Agostinho, ao sul por Sirinhaém, a oeste por Escada e a leste pelo Oceano Atlântico.

O município de Sirinhaém está localizado na Região Intermediária de Recife e é um dos municípios polos da Região Imediata Barreiros – Sirinhaém (IBGE, 2017). Sua sede dista a 80 km da cidade de Recife. Limita-se ao norte com os municípios de Ipojuca e Escada, ao sul com Rio Formoso e Tamandaré, a leste com o Oceano Atlântico e a oeste com Ribeirão. Sua área de unidade territorial é de 374,321 km<sup>2</sup> e sua população estimada em 2021 era de 46.845 habitantes (IBGE, 2021). Seu território é composto pela sede Sirinhaém e dos distritos de Barra de Sirinhaém, Santo Amaro e Ibaratinga.

A região do estuário ocupa uma área aproximada de 40 km<sup>2</sup>. Encontra-se nas planícies costeiras que se formaram durante a transgressão marinha do Holoceno, inundando os vales dos rios. Apresenta baixas profundidades, com topografia semelhantes ao vale dos rios, com seção transversal aumentando em direção à foz (SILVA et al., 2007).

O clima é quente e úmido pseudo-tropical, do tipo As', segundo Köppen. O regime pluviométrico varia entre 1.850 a 2.364 mm anuais, com chuvas abundantes entre junho e agosto. A temperatura registra médias anuais entre 25 °C e 30 °C (SILVA, 2009). O bioma característico é a mata atlântica e seus ecossistemas associados: manguezal e restinga (AMBITEC, 2008).

Figura 4 – Localização da área de estudo



Fonte: o autor, 2022.

Na região existem duas Unidades de Conservação. Nossa área de estudo está parcialmente inserida na APA de Sirinhaém criada pelo Decreto Estadual nº 21.229/1998 e abrangendo uma área de 6.589 hectares. E totalmente inserida na APA estuarina dos rios Sirinhaém e Maracaípe, criada pela Lei nº 9.931/1986 com área total de 3.335 hectares. O grande objetivo dessas áreas é contribuir, de forma geral, para a conservação, preservação, recuperação e restauração desses ecossistemas (APAC, 2013).



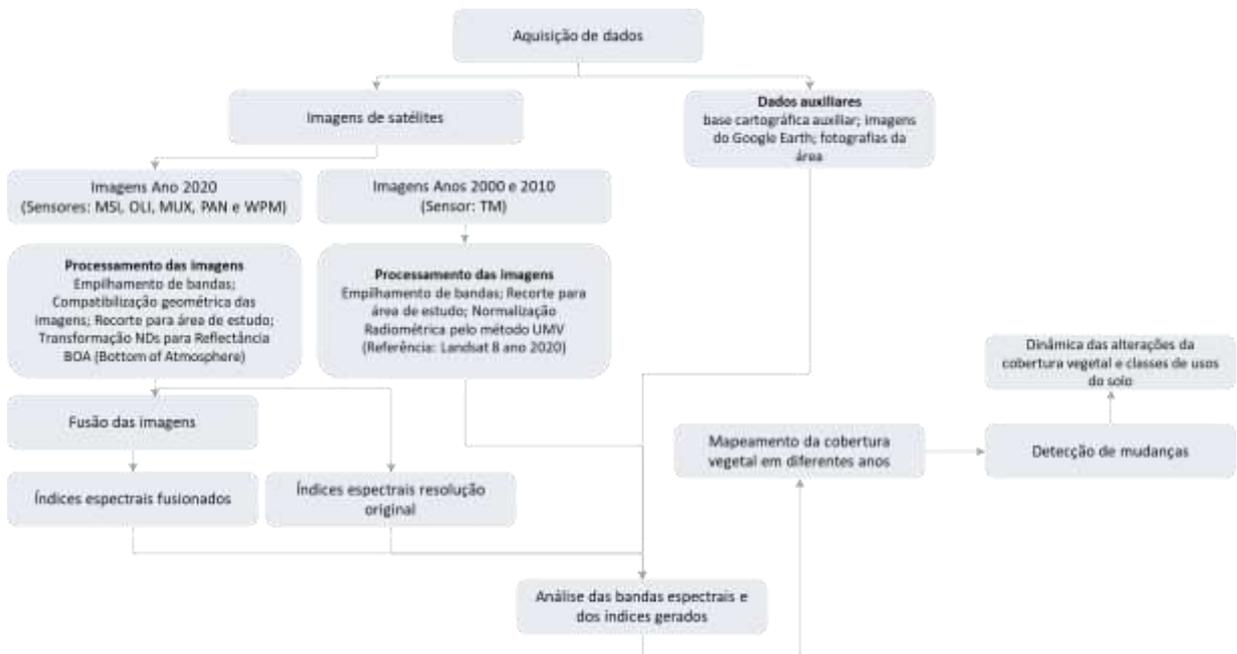
Félix, São Joaquim do Monte e Sairé, ambos inseridos na região do Agreste, não desenvolvem atividade agrícola da cana-de-açúcar (APAC, 2013).

No baixo curso da bacia, encontramos o estuário dos rios Formoso e Sirinhaém. Coexistindo com a produção de cana-de-açúcar, a região também abriga várias comunidades tradicionais de pescadores artesanais. Silva Júnior (2011) e Silva (2014) nos relatam como essa atividade vem perdendo espaço e sofrendo por conflitos com origem na concentração de terras e o monocultivo da cana-de-açúcar. Mais recentemente também há uma crescente nas atividades de turismo, que pode ser constatado a partir de inúmeras casas de veraneio e *resorts* que se instalaram na região. Os impactos desse crescimento refletem-se na diminuição da quantidade de pescadores, nos deslocamentos forçados da população agrícola local, no aumento da violência e também no meio ambiente (SILVA JÚNIOR, 2011; SILVA, 2014).

### 3.2 METODOLOGIA

Os passos metodológicos que foram executados para aquisição e processamento dos dados utilizados com vistas a alcançar os objetivos dessa pesquisa são apresentados na Figura 6 a seguir:

Figura 6 – Fluxograma da metodologia de aquisição e processamento dos dados



Fonte: o autor, 2022.

### 3.2.1 Aquisição e processamento das imagens

As imagens utilizadas nas análises desse estudo foram adquiridas nos catálogos da USGS (<https://earthexplorer.usgs.gov/>) e do INPE (<http://www.dgi.inpe.br/catalogo/>). O Quadro 1 apresenta as informações acerca das imagens utilizadas nesse estudo. O critério de escolha para as imagens adotado no trabalho considera a menor presença de nuvens na cena e a data de aquisição para períodos mais próximos de ambos os satélites utilizados, além disso, concentramos a escolha das imagens nos meses de setembro a dezembro, tendo em vista a menor ocorrência de chuvas nessa época do ano na área de estudo (ver Gráfico 1). Também monitoramos os dados de precipitação diária com o intuito de verificar a ocorrências de grandes chuvas no dia ou nos dias que antecederam a aquisição das imagens pelos sensores (Figura 7).

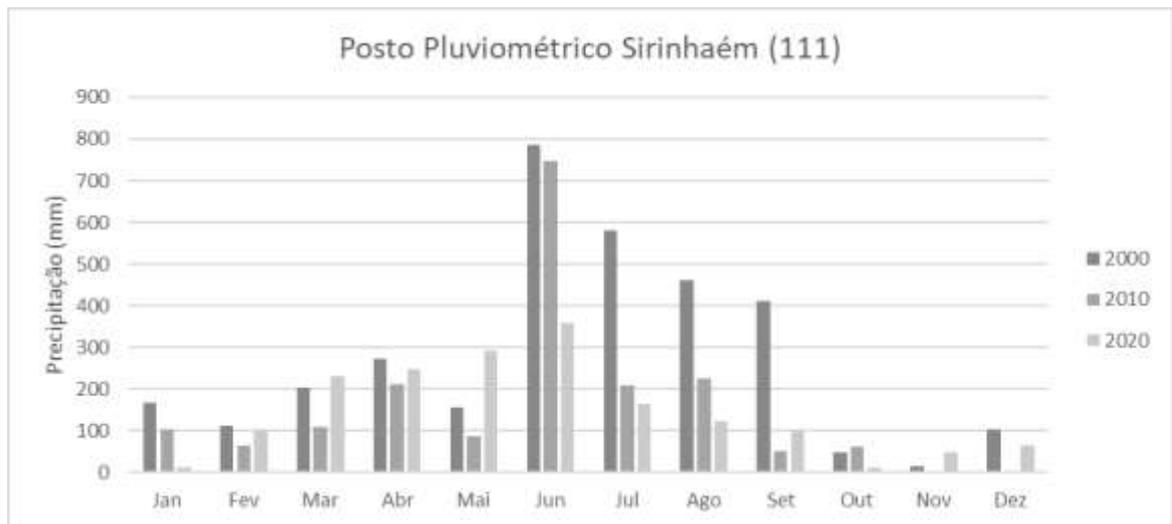
Além das imagens de satélite, outros dados cartográficos auxiliares também foram adquiridos, tais como: rodovias, hidrografia, núcleos urbanos, imagens do Google Earth, dentre outros, com o propósito de facilitar a identificação de alvos na área de estudo.

Quadro 1 – Imagens empregadas na pesquisa

<b>Data das imagens</b>	<b>Satélite</b>	<b>Sensor/Bandas</b>	<b>Nível de Processamento</b>
14/09/2020	Sentinel-2	MSI Bandas: 2(azul), 3(verde), 4(vermelho), 8(infravermelho próximo)	L1C – Top-of-atmosphere (TOA) reflectance data. Inclui correção radiométrica e geométrica (ortorretificação).
06/12/2020	Landsat 8	OLI Bandas: 2(azul), 3(verde), 4(vermelho), 5(infravermelho próximo), 8(pancromática)	L1TP – dados OLI e TIRS com correção radiométrica e geométrica (ortorretificado)
27/08/2020	CBERS-4	PAN Bandas: 1(pancromática), 2(verde), 3(vermelho), 4(infravermelho)  MUX Bandas: 5(azul), 6(verde), 7(vermelho), 8(infravermelho próximo)	L2 – imagem com correção radiométrica e correção geométrica de sistema, na qual usam-se dados de efemérides e de altitude recebidos do satélite juntamente com a imagem.
29/12/2020	CBERS-4A	MUX Bandas: 5(azul), 6(verde), 7(vermelho), 8(infravermelho próximo)  WPM Bandas: 0(pan), 1(azul), 2(verde), 3(vermelho), 4(infravermelho próximo)	
12/10/2000 27/12/2010	Landsat-5	TM Bandas: 1(azul), 2(verde), 3(vermelho), 4(infravermelho próximo), 5(infravermelho médio), 6(infravermelho médio).	L1TP – dados com correção radiométrica e geométrica (ortorretificado)

Fonte: o autor, 2022.

Gráfico 1 – Valores mensais de precipitação na área de estudo, anos 2000, 2010 e 2020



Fonte: APAC, 2022.

Figura 7 – Valores diários de precipitação nas datas de aquisição das imagens

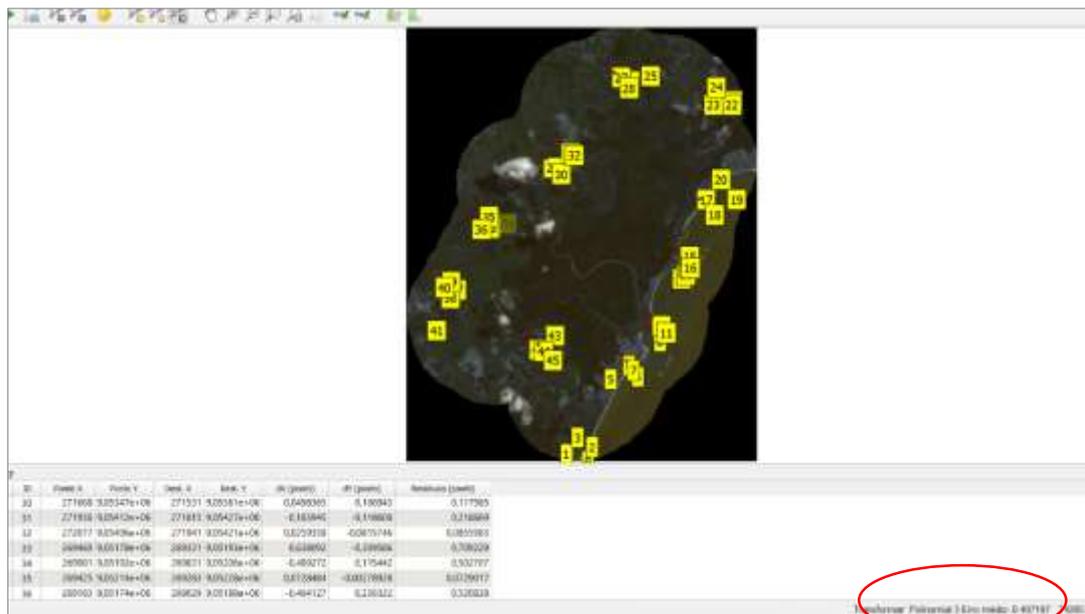
Mês/Ano - Outubro/2000						
Dia do mês	9	10	11	<b>12</b>	13	14
Precipitação (mm)	0	1	8	0	0	13
Mês/Ano - Dezembro/2010						
Dia do mês	24	25	26	<b>27</b>	28	29
Precipitação (mm)	0	0	0	0	0	0
Mês/Ano - Agosto/2020						
Dia do mês	24	25	26	<b>27</b>	28	29
Precipitação (mm)	0	0	5	0	0	4
Mês/Ano - Setembro/2020						
Dia do mês	11	12	13	<b>14</b>	15	16
Precipitação (mm)	0	0	0	0	0	2
Mês/Ano - Dezembro/2020						
Dia do mês	3	4	5	<b>6</b>	7	8
Precipitação (mm)	0	0	0	0	0	0
Mês/Ano - Dezembro/2020						
Dia do mês	26	27	28	<b>29</b>	30	31
Precipitação (mm)	0	0	0	0	0	0
dia da aquisição da imagem						

Fonte: o autor, 2022.

Após a aquisição, as bandas multiespectrais das imagens foram empilhadas utilizando o *software* QGIS. Os dados CBERS, que normalmente apresentam inconsistências geométricas, com deslocamentos posicionais incompatíveis com o elemento de resolução espacial, conforme descrito em (AKIYAMA; MARCATO; TOMMASELLI, 2018; JUNIOR et al., 2017),

passaram por análise criteriosa e detectou-se a necessidade de realizar compatibilização geométrica com as demais imagens. Para isso foram empregados cerca de 46 pontos de controle (GCP) com coordenadas UTM fuso 25 Sul, obtidos a partir da composição colorida normal da imagem Sentinel-2, em virtude de a mesma apresentar a melhor resolução espacial nativa dentre os sensores. Para esta etapa, adotou-se como critério de qualidade de georreferenciamento das imagens um erro médio igual ou inferior a 0,5 pixel (ver Figura 8). A partir daí, recortamos as imagens para o polígono representativo da área de estudo utilizando o limite de cobertura vegetal do mapeamento realizado pelo projeto MapBiomas, coleção 6, disponível em (<https://mapbiomas.org/download>) e iniciamos o processo de transformação dos valores digitais dos pixels para reflectância.

Figura 8 – Ferramenta Georreferenciador do *software* QGIS



Fonte: o autor, 2022.

## Transformação de ND para Radiância e Reflectância

Os dados das imagens obtidas nos sensores são armazenados como números digitais (ND). OS dados de NDs precisam ser convertidos para radiância num primeiro momento, posteriormente para reflectância aparente no topo da atmosfera (*Top of Atmosphere - TOA*) e por fim, por meio da aplicação de métodos de correção atmosférica, para reflectância de superfície (*Bottom of Atmosphere - BOA*).

Para a realização dessa etapa, buscamos utilizar os melhores dados disponíveis para cada um dos sensores envolvidos na pesquisa. A transformação das imagens OLI/Landsat-8 e MSI/Sentinel-2 foram realizadas de forma automática pelo *software* QGIS 3.10 com o complemento *Semi Automatic Classification Plugin* (SCP). Os sensores dos satélites CBERS não contam com a divulgação constante dos parâmetros de transformação de ND para reflectância, para alguns desses sensores, apenas dados de calibração pré-lançamento estavam disponíveis. Para o sensor MUX/CBERS-4A utilizamos o coeficiente de calibração absoluta, dado presente no arquivo .xml que acompanha o arquivo de imagem em cada banda. Dentre todos os sensores utilizados na pesquisa, apenas para o sensor WPM/CBERS-4A não houve possibilidade de realizar a transformação para valores de reflectância por não ter sido localizado os parâmetros de calibração necessários, o que nos levou a confecção dos índices físicos com os valores de NDs bruto da imagem. Esse fato nos impede de realizar comparações diretas entre esses dados e os demais sensores, todavia, a fim de constatar a sensibilidade desse sensor para os dados de vegetação e verificar se os índices gerados iriam diferir significativamente dos demais, resolvemos mantê-lo na pesquisa.

Os parâmetros utilizados para os sensores CBERS estão especificados nas Tabelas 1 e 2 abaixo.

Tabela 1 – Parâmetros de calibração CBERS-4

Sensor/satélite	Bandas espectrais ( $\mu\text{m}$ )	Ganho	Offset	ESUN	Fonte
MUX/CBERS-4	Blue (0,45 a 0,52)	1,216929	34,083071	1958	Parâmetros calculados a partir das equações demonstradas em Pinto (2016);
	Green (0,52 a 0,59)	1,3223228	24,376772	1852	
	Red (0,63 a 0,69)	1,336220	11,56378	1559	
	NIR (0,77 a 0,89)	1,047638	7,852362	1091	
PAN/CBERS-4	Pan (0,51 a 0,81)	0,822835	17,177165	1210,49	Dados obtidos em Ponzoni & Epiphanyo (2012) e Pinto (et al., 2016).
	Blue (0,52 a 0,59)	1,185039	36,814961	1549,49	
	Green (0,63 a 0,69)	1,185039	25,814961	1311,81	
	Red (0,77 a 0,89)	0,925197	15,074803	892,31	

Fonte: o autor, 2022.

Tabela 2 – Parâmetros de calibração para o sensor MUX/CBERS-4A

Sensor/satélite	Bandas espectrais ( $\mu\text{m}$ )	CCn	ESUN	Fonte
MUX/CBERS-4A	Blue (0,45 a 0,52)	0,947982	1958	CCn = coeficiente de calibração absoluta presente no arquivo .XML de cada banda; ESUN = utilizamos os mesmos valores do sensor MUX/CBERS-4 - Pinto (et al., 2016).
	Green (0,52 a 0,59)	0,965583	1852	
	Red (0,63 a 0,69)	0,946315	1559	
	NIR (0,77 a 0,89)	0,739644	1091	

Fonte: o autor, 2022.

Nesse processo, o primeiro passo é a conversão do número digital (ND) para radiância espectral  $L_\lambda$  ( $\text{W}/(\text{m}^2 \cdot \text{sr} \cdot \mu\text{m})$ ) que pode ser feita utilizando a Equação 7 a seguir (Pinto, 2016):

$$L_\lambda = \text{ganho} * \text{ND} + \text{offset} \quad (7)$$

Onde:

$L_\lambda$ = radiância espectral em um determinado comprimento de onda ( $\lambda$ );

ND = número digital do pixel;

Ganho e offset são parâmetros de calibração para cada sensor

Para os dados OLI/Landsat-8, o ganho equivale ao coeficiente RADIANCE\_MULT\_BAND e o offset ao parâmetro RADIANCE\_ADD\_BAND presentes no arquivo .MTL que acompanha as imagens baixadas.

Os dados de ganho e offset para o sensor PAN/CBERS-4 foram calculados a partir das Equações 8 a 10 demonstradas em Pinto (2016):

$$\text{Ganho} = \frac{L_{\max} - L_{\min}}{DN_{\max} - DN_{\min}} \quad (8)$$

Onde:

$L_{\max}$ = radiância máxima

$L_{\min}$ = radiância mínima

$DN_{\max}$ = número digital máximo

$DN_{\min}$ =número digital mínimo

Já o fator offset é calculado para cada banda:

$$offset = L_{min} - Ganho \times DN_{min} \quad (9)$$

Para calcular a irradiância solar utilizamos a seguinte fórmula:

$$ESUN = (\pi \times d^2) \times \frac{L_{max}}{Reflec_{max}} \quad (10)$$

Onde:

ESUN= irradiância solar

$d^2$ = distância Terra-Sol

Reflec<sub>max</sub>= reflectância máxima

Para os dados do sensor MUX/CBERS-4A a transformação para radiância foi realizada mediante os coeficientes de calibração absoluta constantes no arquivo .XML que acompanha cada banda da imagem. Por esse motivo, a equação utilizada para a transformação foi a que segue abaixo (PONZONI; JUNIOR; LAMPARELLI, 2005):

$$L_{\lambda} = \frac{ND_n}{CC_n} \quad (11)$$

Onde:

$L_{\lambda}$ = radiância espectral aparente;

ND<sub>n</sub>= número digital extraído da imagem na banda n

CC<sub>n</sub>= coeficiente de calibração absoluta para a banda n

O próximo passo é a transformação dos valores de radiância espectral para valores de reflectância TOA. Essa transformação pode ser executada aplicando a Equação 12 a seguir (PINTO, 2016):

$$\rho_{\lambda} = \frac{\pi \times L_{\lambda} \times d^2}{ESUN \times \cos(\theta_{SZ})} \quad (12)$$

Onde:

$\rho_{\lambda}$  = é a reflectância aparente ou de topo da atmosfera;

$\theta_{SZ}$  = ângulo zenital solar definido por  $\theta_{SZ} = 90 - \theta_{SE}$

$\theta_{SE}$  = ângulo de elevação solar

Os dados de reflectância aparente não representam o brilho exclusivo do alvo observado, pois possuem interferência devido aos processos de espalhamento e absorção pelos gases e partículas que compõem a atmosfera. Para transformar os valores de reflectância aparente (TOA) em reflectância de superfície (BOA) podemos aplicar a Equação 13 (SOBRINO; JIMÉNEZ-MUÑOZ; PAOLINI, 2004):

$$\rho = \frac{\pi \times (L_{\lambda} - L_p) \times d^2}{\tau_v * ((ESUN * \cos(\theta_{SZ}) * \tau_z) + E_{down})} \quad (13)$$

Onde:

$\rho$  = reflectância de superfície

$L_p$  = radiância de subtração

$\tau_v$  = transmitância da atmosfera no ângulo de visada

$\tau_z$  = transmitância da atmosfera no ângulo de iluminação

$E_{down}$  = radiância difusa de *downwelling*

A correção atmosférica utilizando parâmetros da própria imagem, desenvolvido por Chavez (1996) é chamado método DOS (*Dark Object Subtraction*). A metodologia para o cálculo dessa correção foi replicada a partir daquela descrita em SOBRINO; JIMÉNEZ-MUÑOZ; PAOLINI (2004) e CONGEDO (2021). Essa correção envolve a transformação dos NDs da imagem para radiância para posterior subtração da radiância do objeto escuro, que equivale a 1% da reflectância. A radiância de subtração ( $L_p$ ) é obtida através da seguinte Equação 14:

$$L_p = L_{min} - L_{1\%} \quad (14)$$

Onde:

$L_p$ = radiância de subtração

$L_{min}$ = a radiância obtida com o valor digital de contagem equivalente ao  $DN_{min}$ .

$L_{1\%}$ = radiância do objeto escuro

A radiância do objeto escuro pode ser obtida pela equação 15:

$$L_{1\%} = 0.01 * [(ESUN * \cos\theta_s * T_z) + E_{down}] * \frac{T_v}{\pi * d^2} \quad (15)$$

A mesma metodologia de correção atmosférica foi replicada para todas as imagens da pesquisa, utilizando-se para isso a calculadora raster do *software* QGIS.

Para as imagens dos anos 2000 e 2010 e afim de subsidiar o estudo multitemporal, realizamos o procedimento de normalização radiométrica pelo método de uniformização das médias e variâncias (UMV). Este método, consiste em igualar as médias e variâncias de duas imagens a partir de uma transformação linear, tendo sido uma escolhida como referência e a outra como de ajuste. A imagem referência foi a mesma para as duas datas: a imagem Landsat 8 do ano de 2020. No primeiro momento, dados estatísticos das imagens são coletados para o cálculo dos parâmetros de Ganho e Offset (equações 16 e 17) e em seguida, as imagens de ajustes são ajustadas aplicando-se os parâmetros conforme Equação 18 (ROSA DOS SANTOS; MACHADO; SAITO, 2010).

$$GANHO = \sqrt{\frac{\sigma_R^2}{\sigma_A^2}} \quad (16)$$

$$OFFSET = \mu_R - GANHO * \mu_A \quad (17)$$

$$A' = A * GANHO + OFFSET \quad (18)$$

Onde:

$\sigma^2_R$  = variância da imagem de referência;

$\sigma^2_A$  = variância da imagem de ajuste;

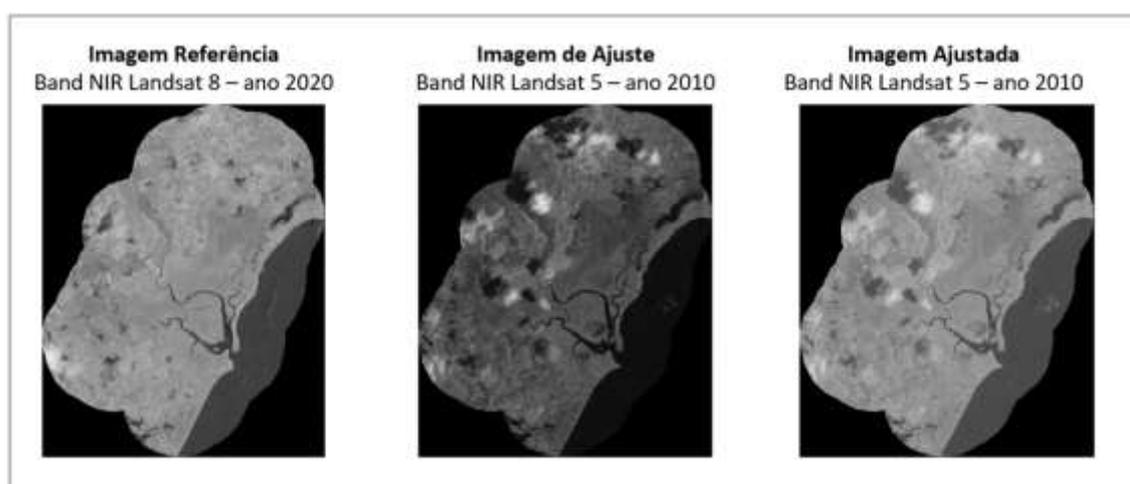
$\mu_R$  = média da imagem de referência;

$\mu^A$  = média da imagem de ajuste;

$A'$  = imagem ajustada;

Na Figura 9 apresentamos um exemplo do resultado obtido no procedimento.

Figura 9 – Comparação entre a imagem referência e a imagem ajustada pelo processo de normalização radiométrica



Fonte: o autor, 2022.

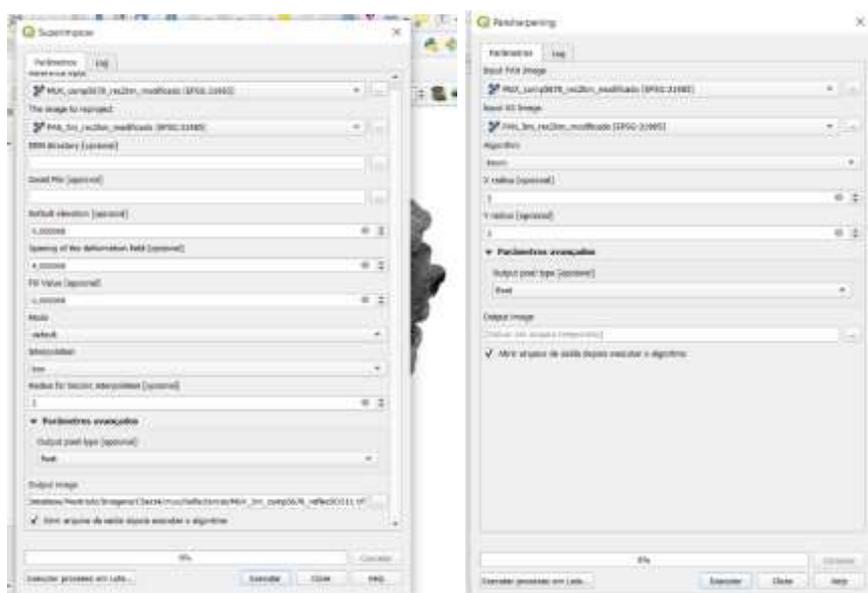
## Fusão das imagens

Visando a utilização de todo o potencial das imagens disponíveis livremente empregadas nessa pesquisa, procedemos com a fusão dos dados multiespectrais com as bandas pancromáticas disponíveis em cada sensor para as imagens do ano 2020. Com essa operação, há uma melhoria com relação a resolução espacial das imagens e podendo resultar em melhores condições de identificação dos alvos. Por esse motivo, os índices empregados nessa pesquisa foram calculados a partir das imagens em resolução nativa e também nas imagens fusionadas, a fim de serem comparadas entre si.

As fusões das bandas foram realizadas por meio da ferramenta ORFEO Toolbox (OTB) implementados no *software* QGIS. O método de fusão empregado foi o *Pansharpenig (Local Mean and Variance Matching)*. Esse método proporciona grande fidelidade espacial e espectral,

com coeficiente de correlação superior a 0,9 com a imagem original, quando comparado com outras nove técnicas de fusão (WITHARANA; CIVCO; MEYER, 2013). Os procedimentos para a aplicação dessa técnica envolvem primeiro a aplicação da ferramenta *superimpose*, que dimensiona e compatibiliza a imagem a ser fusionada para a extensão e resolução da banda pancromática empregada; posteriormente, a ferramenta *Pansharpning* LMVM para mesclar as cenas (ver Figura 10).

Figura 10 – Interface das ferramentas *Superimpose* e *Pansharpning* no software QGIS



Fonte: o autor, 2022.

### 3.2.2 Geração dos índices de vegetação

O passo seguinte foi a obtenção dos índices empregados nessa pesquisa, calculados conforme as equações descritas no Quadro 2 abaixo:

Quadro 2 – Índices espectrais utilizados no trabalho

Índice Espectral	Fórmula LANDSAT	Fórmula CBERS	Fórmula Sentinel-2
<b>NDVI</b> (Normalized Difference Vegetation Index)	<b>TM/L5</b> $(\rho_{B4} - \rho_{B3}) / (\rho_{B4} + \rho_{B3})$  <b>OLI/L8</b> $(\rho_{B5} - \rho_{B4}) / (\rho_{B5} + \rho_{B4})$	<b>CCD/CBERS-2 e 2B</b> <b>PAN/CBERS-4</b> <b>WPM/CBERS-4A</b> $(\rho_{B4} - \rho_{B3}) / (\rho_{B4} + \rho_{B3})$  <b>MUX/CBERS-4 e 4A</b> $(\rho_{B8} - \rho_{B7}) / (\rho_{B8} + \rho_{B7})$	<b>MSI/Sentinel-2</b> $(\rho_{B8} - \rho_{B4}) / (\rho_{B8} + \rho_{B4})$
<b>EVI</b> (Enhanced Vegetation Index)	<b>TM/L5</b> $G * \frac{(\rho_{B4} - \rho_{B3})}{L + \rho_{B4} + C_1 * \rho_{B3} - C_2 * \rho_{B1}}$  <b>OLI/L8</b> $G * \frac{(\rho_{B5} - \rho_{B4})}{L + \rho_{B5} + C_1 * \rho_{B4} - C_2 * \rho_{B2}}$	<b>CCD/CBERS-2 e 2B</b> <b>PAN/CBERS-4</b> <b>WPM/CBERS-4A</b> $G * \frac{(\rho_{B4} - \rho_{B3})}{L + \rho_{B4} + C_1 * \rho_{B3} - C_2 * \rho_{B1}}$  <b>MUX/CBERS-4 e 4A</b> $G * \frac{(\rho_{B8} - \rho_{B7})}{L + \rho_{B8} + C_1 * \rho_{B7} - C_2 * \rho_{B5}}$	<b>MSI/Sentinel-2</b> $G * \frac{(\rho_{B8} - \rho_{B4})}{L + \rho_{B8} + C_1 * \rho_{B4} - C_2 * \rho_{B2}}$
<b>SAVI</b> (Soil Adjusted Vegetation Index)	<b>TM/L5</b> $\frac{(1 + L) * (\rho_{B4} - \rho_{B3})}{\rho_{B4} + \rho_{B3} + L}$  <b>OLI/L8</b> $\frac{(1 + L) * (\rho_{B5} - \rho_{B4})}{\rho_{B5} + \rho_{B4} + L}$	<b>CCD/CBERS-2 e 2B</b> <b>PAN/CBERS-4</b> <b>WPM/CBERS-4A</b> $\frac{(1 + L) * (\rho_{B4} - \rho_{B3})}{\rho_{B4} + \rho_{B3} + L}$  <b>MUX/CBERS-4 e 4A</b> $\frac{(1 + L) * (\rho_{B8} - \rho_{B7})}{\rho_{B8} + \rho_{B7} + L}$	<b>MSI/Sentinel-2</b> $\frac{(1 + L) * (\rho_{B8} - \rho_{B4})}{\rho_{B8} + \rho_{B4} + L}$
<b>VARI<sub>GREEN</sub></b> (Visible Atmospherically Resistance Index)	<b>TM/L5</b> $\frac{\rho_{B2} - \rho_{B3}}{\rho_{B2} + \rho_{B3} - \rho_{B1}}$  <b>OLI/L8</b> $\frac{\rho_{B3} - \rho_{B4}}{\rho_{B3} + \rho_{B4} - \rho_{B2}}$	<b>CCD/CBERS-2 e 2B</b> <b>WPM/CBERS-4A</b> $\frac{\rho_{B2} - \rho_{B3}}{\rho_{B2} + \rho_{B3} - \rho_{B1}}$  <b>MUX/CBERS-4 e 4A</b> $\frac{\rho_{B6} - \rho_{B7}}{\rho_{B6} + \rho_{B7} - \rho_{B5}}$	<b>MSI/Sentinel-2</b> $\frac{\rho_{B3} - \rho_{B4}}{\rho_{B3} + \rho_{B4} - \rho_{B2}}$
<b>NDWI</b> (Normalized Difference Water Index)	<b>TM/L5</b> $\frac{\rho_{B2} - \rho_{B4}}{\rho_{B2} + \rho_{B4}}$  <b>OLI/L8</b> $\frac{\rho_{B3} - \rho_{B5}}{\rho_{B3} + \rho_{B5}}$	<b>CCD/CBERS-2 e 2B</b> <b>PAN/CBERS-4</b> <b>WPM/CBERS-4A</b> $\frac{\rho_{B2} - \rho_{B4}}{\rho_{B2} + \rho_{B4}}$  <b>MUX/CBERS-4 e 4A</b> $\frac{\rho_{B6} - \rho_{B8}}{\rho_{B6} + \rho_{B8}}$	<b>MSI/Sentinel-2</b> $\frac{\rho_{B3} - \rho_{B8}}{\rho_{B3} + \rho_{B8}}$
<b>ρ<sub>BX</sub></b> = reflectância na banda do número; G = constante igual a 2,5; L (EVI) = valor constante de ajuste do solo igual a 1,0; C1 = constante igual a 6,0; C2 = constante igual a 7,5; L (SAVI) = valor constante de ajuste do solo normalmente igual a 0,5.			

Fonte: (JENSEN, 2009), adaptado.

Em síntese, tendo em conta os diferentes índices, sensores e resoluções elencados na pesquisa, foram gerados 51 produtos para o ano de 2020, 5 para o ano de 2000 e 5 para o ano de 2010, totalizando 61 produtos, conforme Quadro 3 abaixo:

Quadro 3 – Índices gerados e respectivas nomenclaturas utilizadas na pesquisa

Ano	Sensores	Resolução	Índices	Nomenclatura
2020	MSI/Sentinel-2	10m	NDVI SAVI EVI VARIgreen NDWI	MSI_10m_NDVI MSI_10m_SAVI MSI_10m_EVI MSI_10m_VARIgreen MSI_10m_NDWI
	OLI/Landsat-8	30m	NDVI SAVI EVI VARIgreen NDWI	OLI_30m_NDVI OLI_30m_SAVI OLI_30m_EVI OLI_30m_VARIgreen OLI_30m_NDWI
		15m (fusão)	NDVI SAVI EVI VARIgreen NDWI	OLI_15m_NDVI OLI_15m_SAVI OLI_15m_EVI OLI_15m_VARIgreen OLI_15m_NDWI
	MUX/CBERS-4	20m	NDVI SAVI EVI VARIgreen NDWI	MUX_20m_NDVI MUX_20m_SAVI MUX_20m_EVI MUX_20m_VARIgreen MUX_20m_NDWI
		5m (fusão)	NDVI SAVI EVI VARIgreen NDWI	MUX_5m_NDVI MUX_5m_SAVI MUX_5m_EVI MUX_5m_VARIgreen MUX_5m_NDWI
	MUX/CBERS-4A	16m	NDVI SAVI EVI VARIgreen NDWI	MUX4A_16m_NDVI MUX4A_16m_SAVI MUX4A_16m_EVI MUX4A_16m_VARIgreen MUX4A_16m_NDWI
		2m (fusão)	NDVI SAVI EVI VARIgreen NDWI	MUX4A_2m_NDVI MUX4A_2m_SAVI MUX4A_2m_EVI MUX4A_2m_VARIgreen MUX4A_2m_NDWI
	PAN/CBERS-4	10m	NDVI SAVI NDWI	PAN_10m_NDVI PAN_10m_SAVI PAN_10m_NDWI
		5m (fusão)	NDVI SAVI NDWI	PAN_5m_NDVI PAN_5m_SAVI PAN_5m_NDWI
	WPM/CBERS-4A	8m	NDVI SAVI EVI VARIgreen NDWI	WPM_8m_NDVI WPM_8m_SAVI WPM_8m_EVI WPM_8m_VARIgreen WPM_8m_NDWI
		2m (fusão)	NDVI SAVI EVI VARIgreen NDWI	WPM_2m_NDVI WPM_2m_SAVI WPM_2m_EVI WPM_2m_VARIgreen WPM_2m_NDWI
	2010	TM/LANDSAT-5	30m	NDVI SAVI EVI VARIgreen NDWI
2000	TM/LANDSAT-5	30m	NDVI	TM52000_30m_NDVI

			SAVI EVI VARIgreen NDWI	TM52000_30m_SAVI TM52000_30m_EVI TM52000_30m_VARIgreen TM52000_30m_NDWI
--	--	--	----------------------------------	--

Fonte: o autor, 2022.

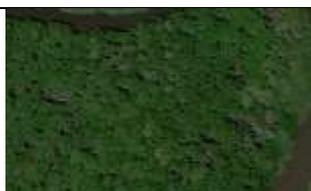
### 3.2.3 Análise dos Dados

A análise da sensibilidade espectral entre os diferentes produtos gerados no estudo foi num primeiro momento avaliada a partir de comparação visual entre os índices especializados e colocados “lado a lado”, classificados numa mesma escala de valores e cores. Além disso, as classes foram quantificadas afim de se melhor avaliar diferenças e semelhanças na representação da cobertura vegetal pelos diferentes índices e sensores, e também nas diferentes resoluções espaciais proporcionadas a partir do processo de fusão das imagens.

Posteriormente, fizemos a obtenção de amostras de valores de pixels nas imagens índices para cinco diferentes classes de cobertura de terra: água b) mosaico agricultura/pastagem c) solo exposto/área urbana d) manguezal 1 e) manguezal 2. Para cada classe, foram selecionadas cinco retângulos com sessenta metros quadrados cada, totalizando então vinte e cinco amostras por imagem, o que corresponde a 1.500 metros quadrados de área em cada imagem.

Para cada amostra, o alvo contido foi estudado utilizando imagens de alta resolução disponíveis nas plataformas Google Earth e BingMaps, mapeamentos prévios da região (SILVA, 2012), MapBiomias (coleção 6) e fotografias da área disponíveis nas plataformas Google Street View e Panoramio. Duas classes diferentes de manguezais foram identificadas a partir dos parâmetros de textura e cor, utilizados como chaves de interpretação. O manguezal tipo 1 foi identificado como tendo uma vegetação densa, com textura rugosa e porte médio/alto, cor verde escuro. O manguezal tipo 2 foi identificado como tendo uma vegetação com porte médio/baixo, textura lisa e cor em tom de verde mais claro. Ver Quadro 4 abaixo:

Quadro 4 – Descrição das classes de cobertura de terra

<b>Alvo</b>	<b>Descrição / chaves de interpretação</b>	<b>Padrão na imagem Google Earth</b>
<b>Água</b>	Corpos hídricos; cor preto (água limpa) ou cinza (água turva). Forma irregular. Geralmente textura lisa (rugosa se houver ondas na superfície).	
<b>Agricultura / Pastagens</b>	Forma regular. Predomínio da cor verde. (pode ser mais claro a depender do tipo e idade do cultivar). Textura lisa.	
<b>Solo Exposto / Áreas Urbanas</b>	Forma irregular (área urbana) ou regular (solo exposto; áreas terraplenadas para loteamento; áreas agrícolas preparadas para cultivo ou recém-colhidas); Maior ocorrência na porção leste da área, junto à praia.	
<b>Manguezal 1</b>	Vegetação densa. Textura rugosa e sombra. Porte médio/alto. Cor verde escuro.	
<b>Manguezal 2</b>	Vegetação arbustiva. Textura lisa. Porte médio/baixo. Cor verde claro.	

Fonte: o autor, 2022.

Por fim, para cada amostra foram extraídos os intervalos de valores dos índices físicos e os plotamos em gráficos do tipo *boxplot* afim de compararmos a sensibilidade espectral desses índices entre os diferentes sensores. A partir desses resultados procedemos o mapeamento da cobertura vegetal da área por meio de um procedimento simples de fatiamento da imagem índice.

## 4 RESULTADOS E DISCUSSÕES

### 4.1 COMPARAÇÃO DE BANDAS ESPECTRAIS ENTRE OS SENSORES OLI, MSI, MUX, PAN E WPM

Inicialmente, as bandas espectrais das faixas do visível e do infravermelho próximo dos sensores estudados foram analisadas e comparadas com vistas a formação de entendimento sobre as diferenças e similaridades que os produtos gerados poderiam oferecer. Para o ano de 2020 foram utilizadas imagens dos sensores: OLI/Landsat-8, MSI/Sentinel-2, MUX e PAN/CBERS-4, MUX e WPM/CBERS-4A. Na Quadro 5 abaixo, é possível visualizar as principais características desses sensores:

Quadro 5 – Principais características dos sensores utilizados no ano de 2020

Sensor/ Satélite	OLI/ Landsat-8	MSI/ Sentinel-2	MUX/ CBERS-4	PAN/ CBERS-4	MUX/ CBERS-4A	WPM/ CBERS-4A
Data das Imagens	06/12/2020	14/09/2020	27/08/2020	27/08/2020	29/12/2020	29/12/2020
Bandas espectrais (µm)	B2(Azul): 0,45 – 0,51	B2(Azul): 0,46 – 0,52	B5(Azul): 0,45 – 0,52	Não possui	B5(Azul): 0,45 – 0,52	B1(Azul): 0,45 – 0,52
	B3(Verde): 0,53 – 0,59	B3(Verde): 0,54 – 0,58	B6(Verde): 0,52 – 0,59	B2(Verde): 0,52 – 0,59	B6(Verde): 0,52 – 0,59	B2(Verde): 0,52 – 0,59
	B4(Vermelho): 0,64 – 0,67	B4(Vermelho): 0,65 – 0,68	B7(Vermelho): 0,63 – 0,69	B3(Vermelho): 0,63 – 0,69	B7(Vermelho): 0,63 – 0,69	B3(Vermelho): 0,63 – 0,69
	B5(NIR): 0,85 – 0,88	B8(NIR): 0,78 – 0,90	B8(NIR): 0,77 – 0,89	B4(NIR): 0,77 – 0,89	B8(NIR): 0,77 – 0,89	B4(NIR): 0,77 – 0,89
	B8(PAN): 0,50 – 0,68			B1(PAN): 0,51 – 0,85		B0(PAN): 0,45 – 0,90
Campo de visada	170 km	290 km	120 km	95 km	95 km	92 km
Resolução espacial	30 m 15 m (PAN)	10 m	20 m	10 m 5 m (PAN)	16 m	8 m 2m (PAN)
Resolução radiométrica	16 bits	12 bits	8 bits	8 bits	8 bits	10 bits
Periodicidade de	16 dias	5 dias	26 dias	52 dias	31 dias	31 dias

Fonte: o autor, 2022.

Os sensores utilizados possuem diferentes resoluções temporais, espectrais e espaciais, além disso, seus dados possuem diferentes níveis de correção geométrica. A plataforma Sentinel-2 possui a melhor resolução temporal dentre eles (5 dias), haja vista operar com dois satélites idênticos em simultâneo: (Sentinel-2A e Sentinel-2B). Depois segue a plataforma

Landsat-8 com 16 dias, CBERS-4 com 26 dias e CBERS-4A com 31 dias. Essa característica tem grande relevância na aquisição de imagens para monitoramento de áreas em regiões de grande incidência de nuvens durante todo o ano, como é o caso da área de estudo, pois significa maior oferta de imagens no intervalo de tempo do estudo.

Em geral, as menores resoluções radiométricas (8 bits: 256 níveis digitais) são encontradas nas plataformas CBERS, com exceção do sensor WPM/CBERS-4A que trabalha em 10 bits. A maior resolução radiométrica foi encontrada nas imagens Landsat-8 (16 bits: 65536 níveis digitais). A plataforma Sentinel-2 gera imagens com 12 bits de resolução radiométrica, o que equivale a 4096 níveis digitais.

Já em relação a resolução espacial, as imagens do sensor WPM/CBERS-4A é a maior, com 8 metros nas imagens multiespectrais e 2 metros na imagem pancromática, seguido pelos sensores PAN/CBERS-4 e MSI/Sentinel-2, que geram imagens com tamanho de pixel equivalente a 10 metros multiespectrais. O sensor PAN ainda oferece uma banda pancromática com resolução de 5 metros. Em seguida temos o sensor MUX/CBERS-4A e MUX/CBERS-4 com 16 e 20 metros, respectivamente. E por fim, as imagens Landsat-8, geradas com tamanho de pixel equivalente a 30 metros. Valderrama-Landeros (*et al.*, 2018), chamaram atenção para o fato que considerando os diferentes tipos de sensores, aqueles com maior resolução espacial podem ser particularmente importantes para o mapeamento de pequenas ilhas de manguezais que costumam ocorrer, principalmente, em sistemas degradados de mangues.

No tocante as características espectrais, percebemos grande similaridade nas três bandas da faixa do visível para todos os sensores. Os valores limítrofes são: Azul (0,45 – 0,52), Verde (0,52 – 0,59) e Vermelho (0,63 – 0,69). Nessa faixa, a maior diferença aparece apenas no espectro do vermelho, onde os sensores a bordo do CBERS-4 e 4A possuem o dobro de largura de banda que os demais. Outra grande diferença é o fato de o sensor PAN/CBERS-4 não possuir a banda espectral do azul. Na faixa do infravermelho próximo, o sensor Landsat-8/OLI possui a menor largura de banda, apenas 0,03  $\mu\text{m}$ , enquanto que os demais sensores são praticamente idênticos, apresentando os valores limítrofes de 0,77 – 0,89.

Após esse primeiro momento, as imagens dos sensores foram transformadas para valores físicos de reflectância BOA e recortadas para a área de estudo, ponto em que foram consultados os dados estatísticos que são apresentados nas tabelas 8 e 9. Há exceção para os dados do sensor WPM/CBERS-4A, onde não foi possível realizar essa transformação e por isso não está presente nas tabelas que seguem.

Tabela 3 – Dados estatísticos das imagens

<b>Bandas</b>	<b>Sensor/Satélite</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Média</b>	<b>Desvio Padrão</b>
Azul	OLI/Landsat-8	0,008	0,281	0,034	0,023
	MSI/Sentinel-2	0,007	0,526	0,042	0,049
	MUX/CBERS-4	0,054	0,326	0,073	0,017
	PAN/CBERS-4	---	---	---	---
	MUX/CBERS-4A	0,019	0,356	0,046	0,023
	WPM/CBERS-4A	---	---	---	---
Verde	OLI/Landsat-8	0,016	0,299	0,061	0,030
	MSI/Sentinel-2	0,011	0,549	0,063	0,050
	MUX/CBERS-4	0,039	0,356	0,069	0,022
	PAN/CBERS-4	0,099	0,743	0,167	0,049
	MUX/CBERS-4A	0,024	0,385	0,063	0,028
	WPM/CBERS-4A	---	---	---	---
Vermelho	OLI/Landsat-8	0,012	0,359	0,063	0,046
	MSI/Sentinel-2	0,009	0,603	0,061	0,060
	MUX/CBERS-4	0,026	0,387	0,059	0,030
	PAN/CBERS-4	0,071	0,876	0,140	0,064
	MUX/CBERS-4A	0,026	0,446	0,073	0,046
	WPM/CBERS-4A	---	---	---	---
Infravermelho Próximo	OLI/Landsat-8	0,000	0,600	0,280	0,071
	MSI/Sentinel-2	0,026	0,651	0,259	0,081
	MUX/CBERS-4	0,021	0,411	0,183	0,049
	PAN/CBERS-4	0,080	0,890	0,407	0,102
	MUX/CBERS-4A	0,051	0,740	0,378	0,083
	WPM/CBERS-4A	---	---	---	---

Fonte: o autor, 2022.

Tabela 4 – Diferenças entre os valores de médias

<b>Bandas</b>	<b>Sensores</b>	<b>Diferença entre as Médias</b>
<b>Azul</b>	OLI X MSI	-0,008
	OLI X MUX	<b>-0,039</b>
	OLI X MUX4A	-0,012
	MSI X MUX	-0,031
	MSI X MUX4A	<b>-0,004</b>
	MUX X MUX4A	0,027
<b>Verde</b>	OLI X MSI	<b>-0,002</b>
	OLI X MUX	-0,008
	OLI X PAN	<b>-0,106</b>
	OLI X MUX4A	<b>-0,002</b>
	MSI X MUX	-0,006
	MSI X PAN	<b>-0,104</b>
	MSI X MUX4A	<b>0</b>
	MUX X PAN	-0,098
	MUX X MUX4A	0,006
	PAN X MUX4A	<b>0,104</b>
<b>Vermelho</b>	OLI X MSI	<b>0,002</b>
	OLI X MUX	0,004
	OLI X PAN	-0,077
	OLI X MUX4A	<b>-0,01</b>
	MSI X MUX	<b>0,002</b>
	MSI X PAN	<b>-0,079</b>
	MSI X MUX4A	-0,012
	MUX X PAN	<b>-0,081</b>
	MUX X MUX4A	-0,014
	PAN X MUX4A	0,067
<b>Infravermelho Próximo</b>	OLI X MSI	<b>0,021</b>
	OLI X MUX	0,097
	OLI X PAN	-0,127
	OLI X MUX4A	-0,098
	MSI X MUX	0,076
	MSI X PAN	-0,148
	MSI X MUX4A	-0,119
	MUX X PAN	<b>-0,224</b>
	MUX X MUX4A	<b>-0,195</b>
	PAN X MUX4A	<b>0,029</b>

\*Valores em vermelho e verde = respectivamente, maiores e menores diferenças encontradas.

Fonte: o autor, 2022.

Ao analisar as tabelas 3 e 4, encontramos valores relativamente próximos nas bandas do espectro do visível, mas os valores de média encontrados nessa faixa diferem mais nas comparações com o sensor PAN. Esse sensor apresentou os maiores valores divergentes na comparação com todos os demais sensores nas faixas do visível (com exceção da banda azul que o mesmo não possui). Os sensores OLI, MSI, MUX e MUX4A apresentaram valores relativamente próximos entre si. Já na faixa espectral do infravermelho próximo, encontramos as maiores diferenças: os valores de média encontrados para os sensores OLI e MSI estão próximos enquanto que há uma maior discrepância desses em relação a todos os demais sensores.

Quanto aos valores de máximo e mínimo, estes podem não apresentar informações passíveis de interpretação, visto serem diretamente afetados pela presença de nuvens e sombras de nuvens no recorte das imagens, sendo, portanto, representações delas. Os valores de desvio padrão são menores no sensor MUX. Isso poderia ser explicado tendo em conta a menor resolução radiométrica deste sensor, todavia, o sensor PAN apresenta-se incoerente quanto a mais este item, visto que possui 8 bits, mas variabilidade de pixels equivalente ao sensor MSI com 12 bits de resolução radiométrica.

## 4.2 ANÁLISE DOS ÍNDICES DE VEGETAÇÃO

Após análise inicial em que as faixas espectrais dos sensores foram comparadas, o passo seguinte é a análise dos índices gerados para estudo da vegetação. Foram gerados cinco diferentes índices espectrais da região de estudo para cada sensor: NDVI, EVI, SAVI,  $VARI_{green}$  e NDWI. Em todos os sensores utilizados, calculamos os índices a partir dos valores de reflectância de superfície, aplicando, inclusive, o mesmo método de correção atmosférica DOS1. Todavia, para o sensor WPM, visto não termos encontrado na literatura, todos os parâmetros necessários para a transformação de ND para reflectância, utilizamos para o cálculo dos índices os valores de ND bruto das imagens, também sem correção atmosférica.

Nos mapas que seguem, fizemos a espacialização dos índices espectrais calculados para os diferentes sensores do estudo, mas preservamos um mesmo intervalo de valores na apresentação, afim de possibilitar comparações visuais entre os produtos gerados. Também quantificamos cada classe do intervalo de valores afim de facilitar esse trabalho.

Para além dos dados apresentados nos mapas, também selecionamos amostras de cinco classes de cobertura de terra presentes nas imagens a fim de realizarmos comparações entre as respostas espectrais dos diferentes sensores/índices/resoluções gerados por meio de gráficos do tipo *boxplot*.

#### **4.2.1 NDVI – Normalized Difference Vegetation Index**

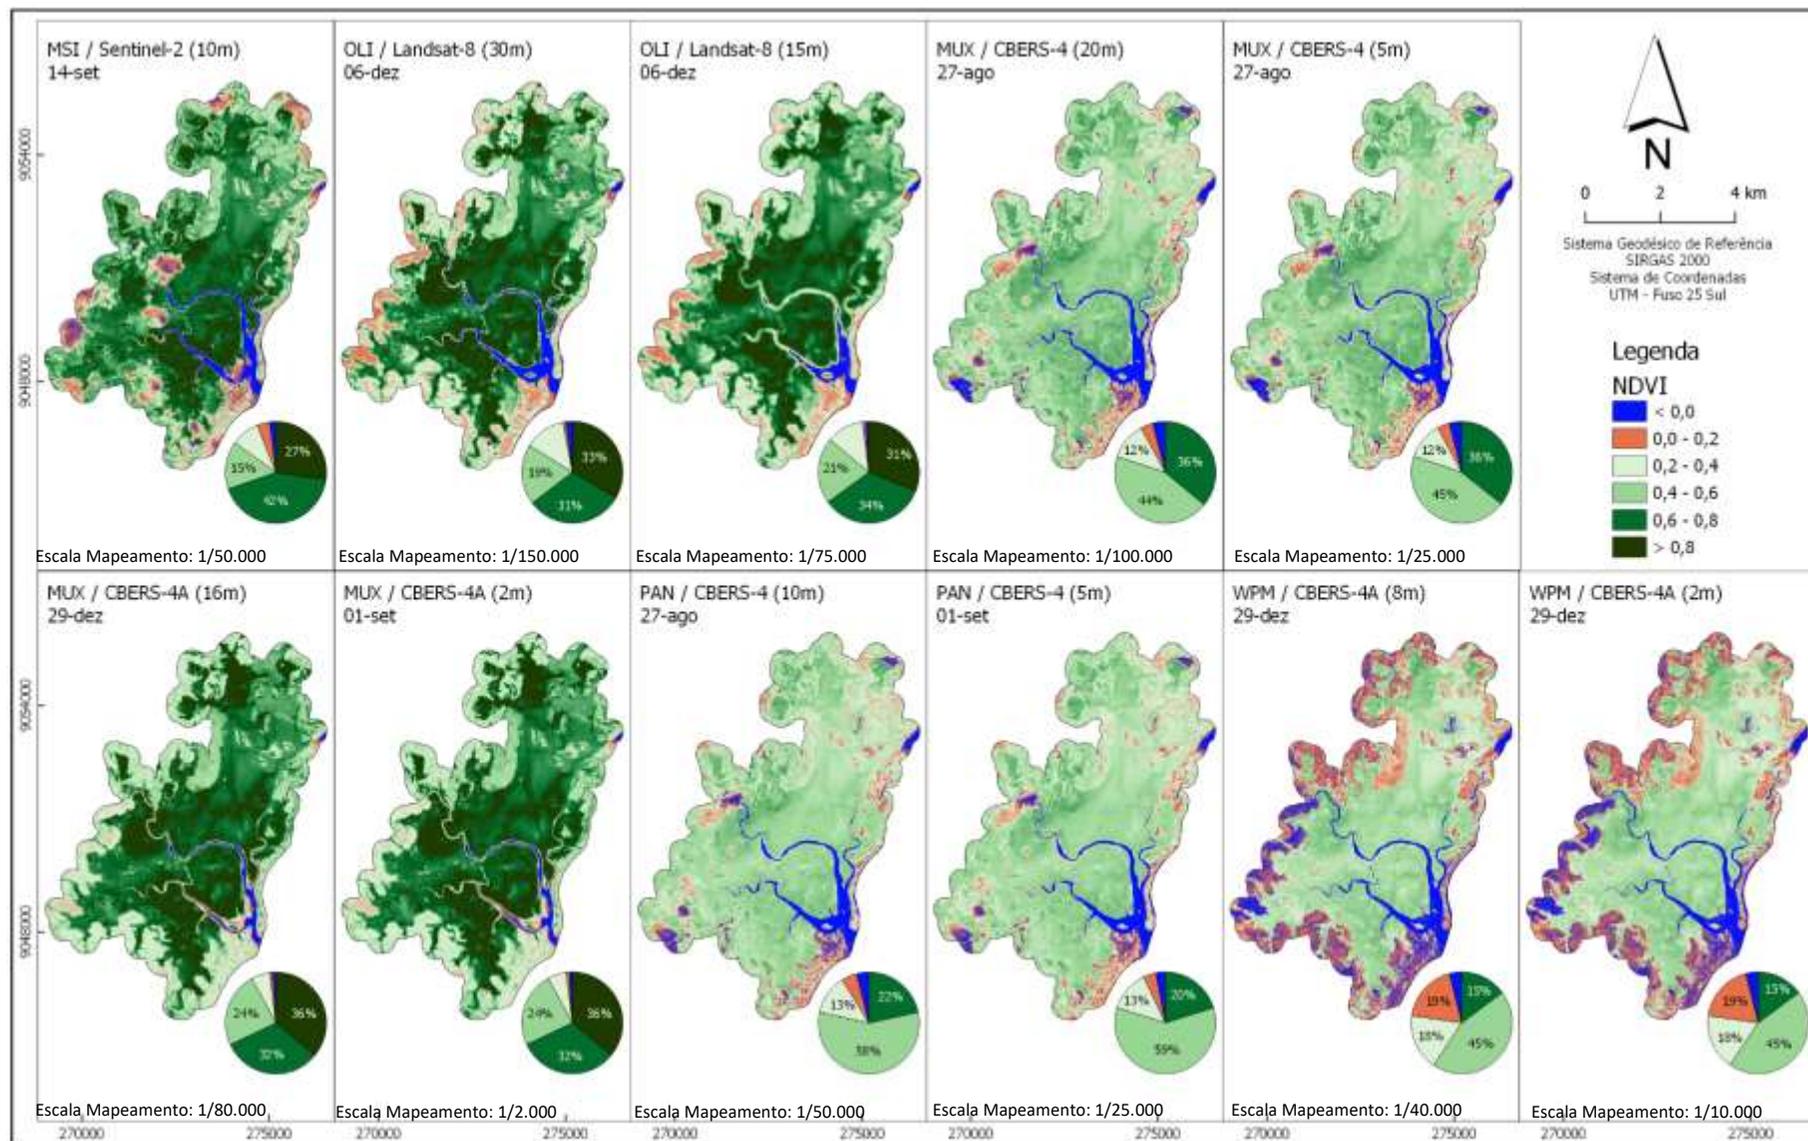
A Figura 11 apresenta valores de NDVI contidos no intervalo de -1 a 1. Foram atribuídas cores para intervalos específicos a partir da análise dos índices e o reconhecimento de alvos (água, vegetação, solo exposto e outros) utilizando dados auxiliares tais como: imagens Google Earth e fotografias da região. A cor azul representa valores negativos de NDVI. Isso significa ausência total de vegetação e é comumente atribuído a alvos como água e nuvens presentes nas imagens. A cor laranja representa valores positivos muito próximos de zero, significando regiões onde há pouca ou nenhuma presença de vegetação, tais como: solo exposto ou com vegetação seca, sombra de nuvens e de relevo e áreas urbanas. A cor verde nas diversas tonalidades representa valores positivos do índice, acima de 0,2, e quanto mais forte a tonalidade, maior a presença de vegetação.

Com a análise dos índices NDVI espacializados constatamos visualmente que o produto gerado pelos sensores MSI, OLI e MUX4A mantiveram-se mais próximos entre si, apresentando uma sensibilidade maior para a vegetação ao atribuir maiores valores de NDVI. Para estes sensores, cerca de, 27%, 33% e 36% dos pixels, respectivamente, apresentaram valores de NDVI superiores a 0,80, o que equivale a uma vegetação de biomassa abundante. Já os produtos dos sensores: MUX, PAN e WPM, apresentaram resultados próximos e no geral, com valores inferiores de NDVI. Para estes sensores, percentuais superiores a 60% dos pixels foram classificados no intervalo de índice de até 0,60. Todavia, podemos afirmar que há similaridades na localização das áreas de maior e menor vigor vegetativo entre todos os produtos gerados, excetuando-se é claro, os locais em que há a ocorrência de nuvens e sombras de nuvens.

As áreas com pouca ou nenhuma presença de vegetação tais como: solo exposto e área urbana (em tons alaranjados e verde mais claro na imagem), foram bem delineadas nos produtos dos sensores OLI, MUX4A e WPM. Isso, em partes, foi devido a data dessas imagens, de dezembro de 2020, em que a maioria das áreas agrícolas da área já haviam sido colhidas e estavam sendo preparadas para o próximo cultivo, significando que uma porcentagem de áreas contabilizadas como vegetação nas outras imagens, tenham sido convertidas em solo exposto

nessas. Esse fato denota ainda que a área de estudo está totalmente envolvida por áreas agrícolas e de pastagens, o que corrobora as observações de Silva (2010) quando indicou que um dos motivos para a diminuição da cobertura vegetal desse estuário estava associada ao desmatamento. Uma análise mais apurada acerca das bordas dos índices pode ser visualizada na Figura 15 (pág. 73).

Figura 11 – Índice NDVI do ano 2020



Fonte: o autor, 2022.

No Gráfico 2 a seguir, apresentamos o gráfico do tipo *box plot* derivados dos intervalos de valores dos índices obtidos para as classes de uso do solo nas imagens. Cada *box plot* retrata a média (pequeno “x”), 1º e 3º quartis (retângulos) e a mediana (linha divisória), além dos valores máximos e mínimos observados nos valores dos pixels das amostras.

No gráfico que traz os valores do índice NDVI constatamos que, no geral, os índices apresentaram valores relativamente próximos comparando o produto com resolução nativa e o produto fusionado. Além disso, apresentaram comportamentos diferentes variando de acordo com o tipo de alvo que está sendo analisado. No alvo água, encontramos a maior variabilidade (amplitude de valores) com mínima em -0,56 (MUX 5m) e máxima em +0,44 (OLI 15m). Os produtos OLI 15m, MUX4A 16m e MUX4A 2m apresentaram dados de água com valores acima de zero, o que consideramos um fato negativo do ponto de vista de identificação de alvos nessas imagens. Era esperado que as águas do Rio Sirinhaém nessa área apresentassem maiores índices de reflectância em virtude dos bancos de areia facilmente identificados nas imagens de alta resolução do Google Earth, todavia, fosse esse fato a causa, em todos os outros sensores deveríamos ter o mesmo panorama.

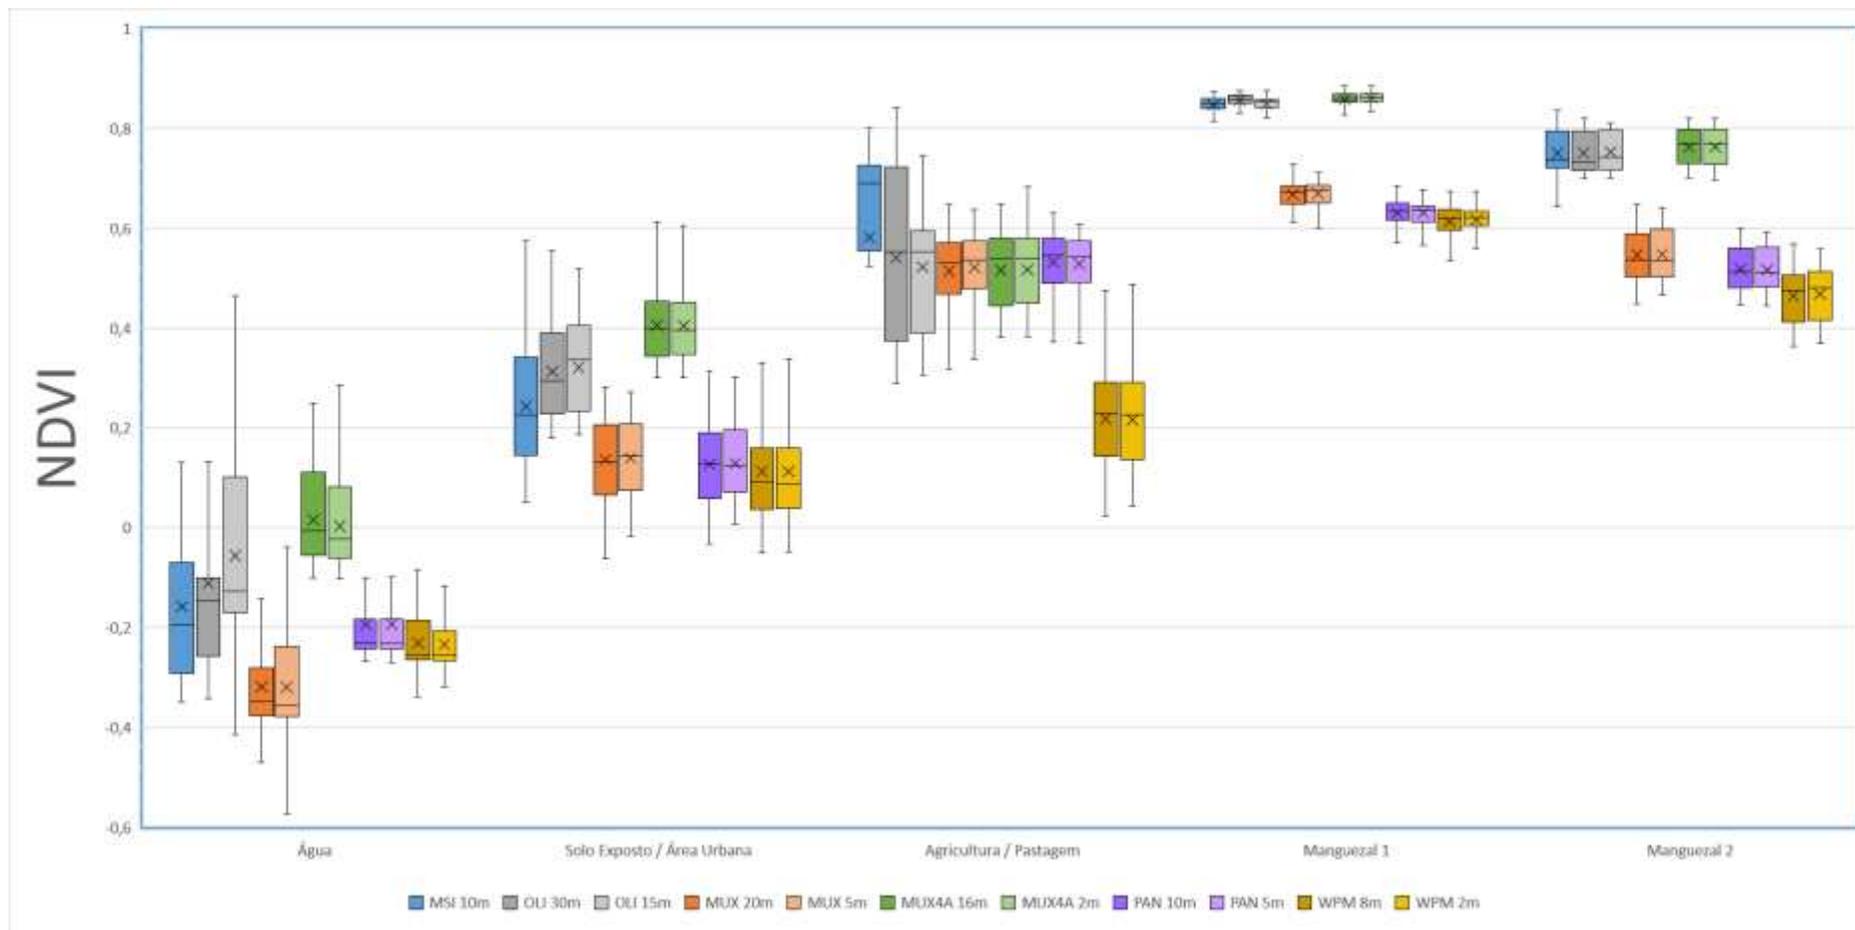
O alvo solo exposto/área urbana apresenta valores levemente superiores aos do alvo água e amplitude de valores entre o -0,04 e +0,6. Novamente, os dados do sensor MUX4A apresentaram valores superiores que os demais sensores. Os produtos MUX, PAN e WPM apresentaram valores similares em média, mediana e 1º e 3º quartis. O alvo agricultura/pastagem apresentou, consistentemente, valores de média e mediana em torno de 0,56 nesse índice NDVI para quase todos os sensores, exceto os sensores MSI e WPM.

Em relação aos alvos com vegetação de mangue, observamos que os dados MSI, OLI e MUX4A ficam próximos entre si e apresentaram dados ligeiramente superiores desse índice que todos os demais sensores. Todavia, apenas nos dados dos sensores OLI e MUX4A podemos visualizar plena separação espectral das duas tipologias de mangue. Nos demais sensores analisados, essa distinção ficou prejudicada, visto que há sobreposição dos valores de máximo e mínimo das amostras analisadas, o que não permite plena separação entre os alvos. Em se tratando da separação entre os alvos de vegetação de mangue e os alvos de agricultura/pastagem, os sensores MSI e MUX4A saíram-se melhor.

Notamos também, que o fato de o índice gerado a partir do sensor WPM/CBERS-4A ter sido calculado a partir dos valores de NDs da imagem e não ter recebido correção atmosférica, não impediu que os dados estivessem próximos daqueles gerados pelos demais sensores que

utilizaram os valores de reflectância, o que corrobora os resultados encontrados em Nascimento (*et al.*, 2020) e Teixeira; Candeias; Tavares Junior, (2017), já que o índice NDVI apresenta pequena diferença entre os dois tipos de produtos e essa diferença não é constante para todos os tipos de alvos. No nosso estudo, apenas no alvo agricultura/pastagem, os valores encontrados no sensor WPM de NDVI apresentaram maiores diferenças que os demais.

Gráfico 2 – Box plot do índice NDVI, ano 2020

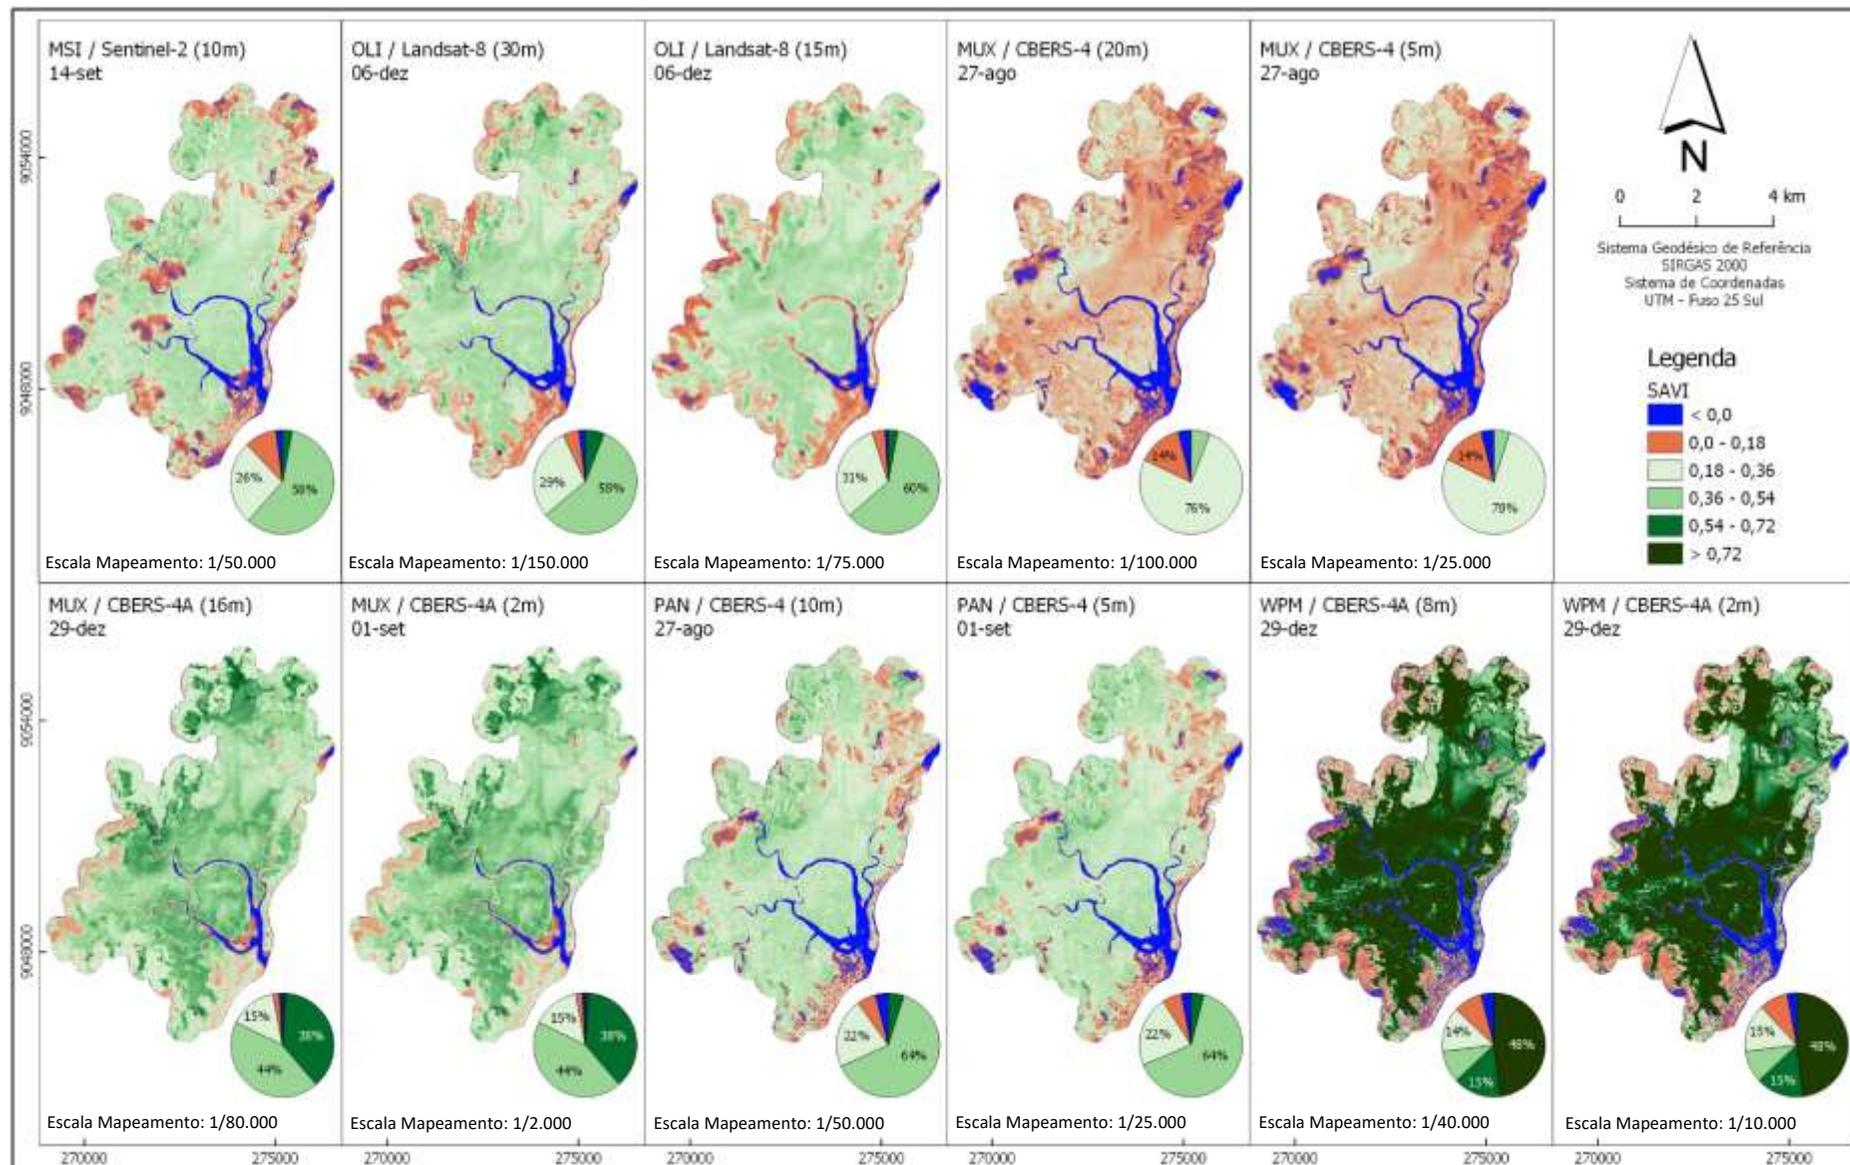


Fonte: o autor, 2022.

#### 4.2.2 SAVI – Soil Adjusted Vegetation Index

Na próxima Figura 12, apresentamos a espacialização do índice SAVI. Esse índice faz uso de uma constante “L”, que tem a função de eliminar os efeitos do solo no resultado final do índice. No nosso trabalho utilizamos o valor “L” igual a 0,5. Segundo Huete e Liu, 1994 (*apud* (JENSEN, 2009), um valor igual a 0,5 minimiza as variações de brilho dos solos e elimina a necessidade de calibrações adicionais. Nessa representação, os intervalos de valores atribuídos para as classes foram levemente inferiores às utilizadas no índice NDVI (variando entre menor  $< 0,0$  e  $> 0,72$ ), todavia, o resultado foi completamente diferente. Podemos facilmente notar visualmente uma diferenciação entre os produtos gerados a partir dos dados de reflectância e o produto calculado a partir dos valores de NDs das imagens, nos mostrando que a falta de calibração dos dados para a confecção desse índice impactou mais que no índice anterior.

Figura 12 – Índice SAVI do ano 2020



Fonte: o autor, 2022.

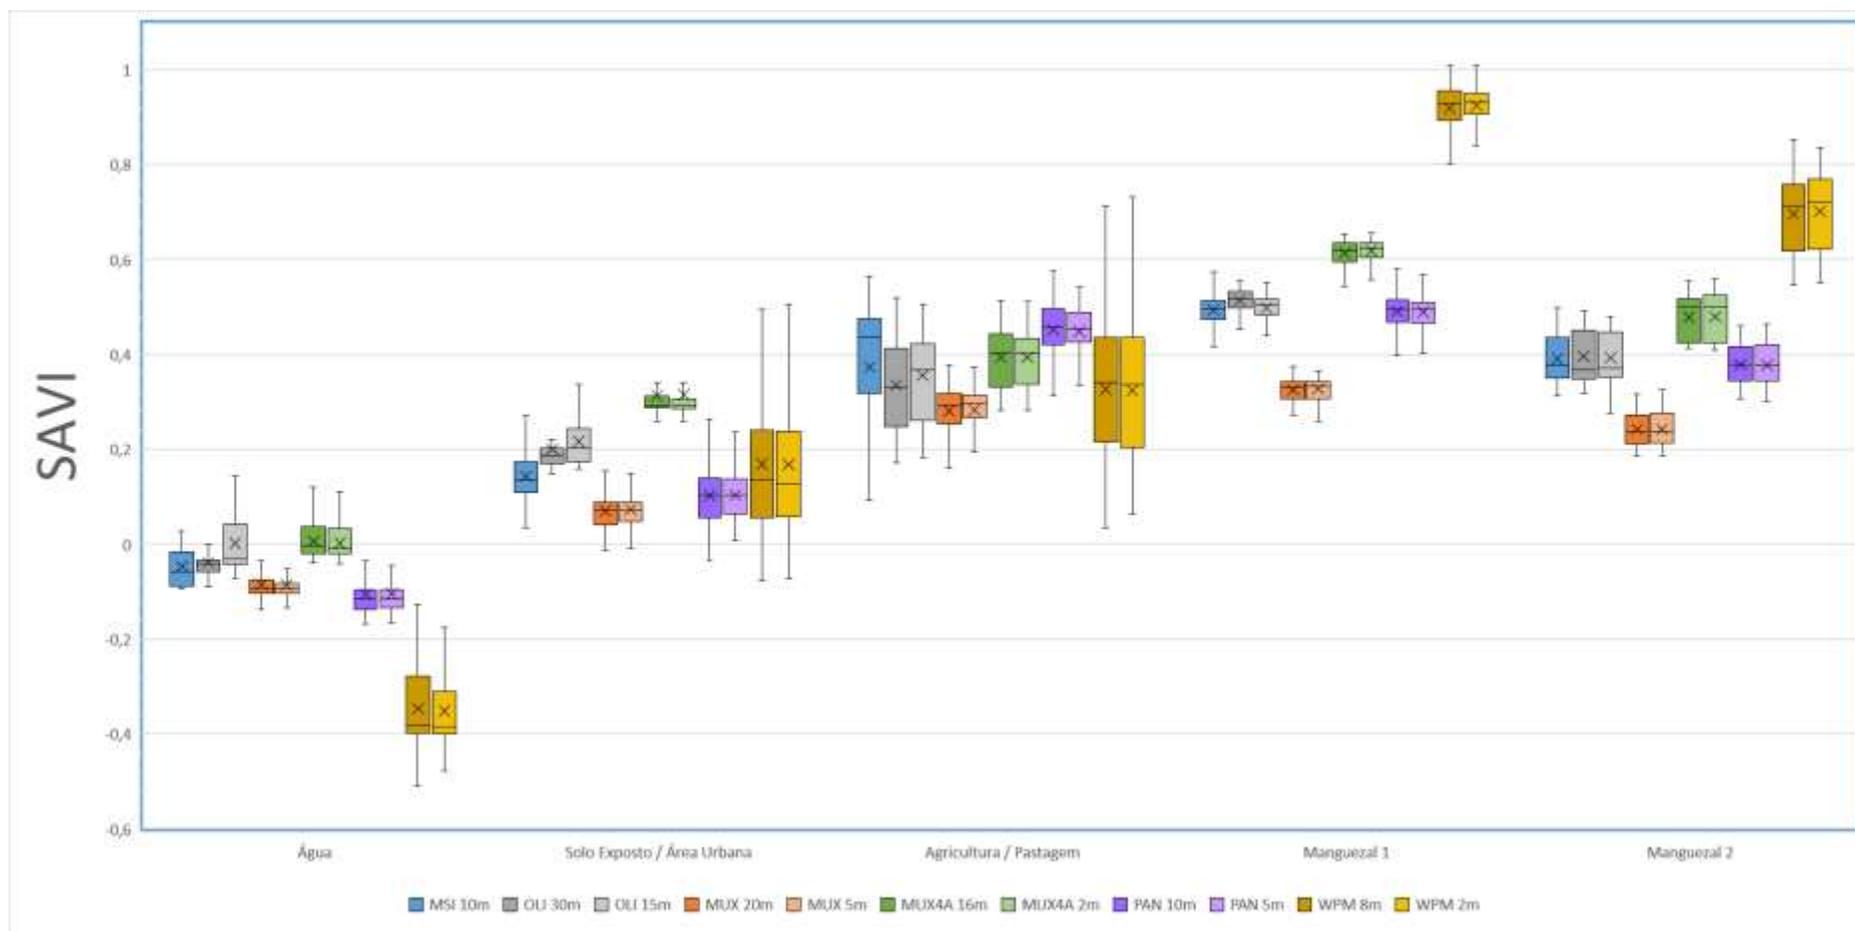
Os índices calculados a partir dos valores de reflectância apresentaram menores valores representativos de vegetação quando comparados ao índice NDVI. Em todos os casos, mais de 85% dos pixels apresentam valores de SAVI de até 0,54. Enquanto que o índice do sensor WPM, calculado a partir dos valores de ND da imagem, apresentou valores significativamente superiores de SAVI, com cerca de 48% dos pixels classificados como maior que 0,72.

Especificamente para os produtos dos sensores MSI e OLI, a dinâmica temporal das culturas agrícolas foram bem destacadas. Na imagem MSI, de 14 de setembro, podemos visualizar essas áreas contabilizadas como vegetação, enquanto na imagem OLI, de 06 de dezembro, as mesmas já haviam sido colhidas. Os sensores da plataforma CBERS-4: MUX e PAN, apresentaram diferenças significativas entre si. Enquanto o sensor MUX apresentou a vegetação em níveis extremamente baixos de índice SAVI, inviabilizando uma análise apurada no intervalo de classes estipulado na figura, o sensor PAN apresentou um quadro mais coerente e próximo dos sensores MSI e OLI.

No Gráfico 3 que traz o gráfico *box plot* com as amostras do índice SAVI verificamos que os dados de vegetação apresentam valores inferiores aos encontrados no índice NDVI e que a sobreposição dos valores de máximo e de mínima nesse índice inviabiliza a plena separação entre as duas tipologias de mangue analisadas. Notamos ainda que há significativa sobreposição dos valores das amostras de solo exposto/área urbana, agricultura/pastagem e vegetação de mangue 1 e 2, fato que prejudica os processos de mapeamento da cobertura do solo da área apenas pelas variáveis espectrais.

Ainda sobre o índice SAVI aplicado, não observamos o erro relatado por alguns autores quando da geração desse índice utilizando o sensor MUX do satélite CBERS-4. Neves e Mucida (2020) encontraram um erro para as imagens CBERS-4 e valores discrepantes para o Landsat-8 quando da geração do índice SAVI, e atribuíram o fato ao valor utilizado na constante “L” aplicada em vegetação pouco densa. Quanto ao nosso estudo, e sua aplicação em vegetação de mangue, com média/alta densidade, os valores encontrados apresentaram-se coerentes.

Gráfico 3 – Box plot do índice SAVI, ano 2020



Fonte: o autor, 2022.

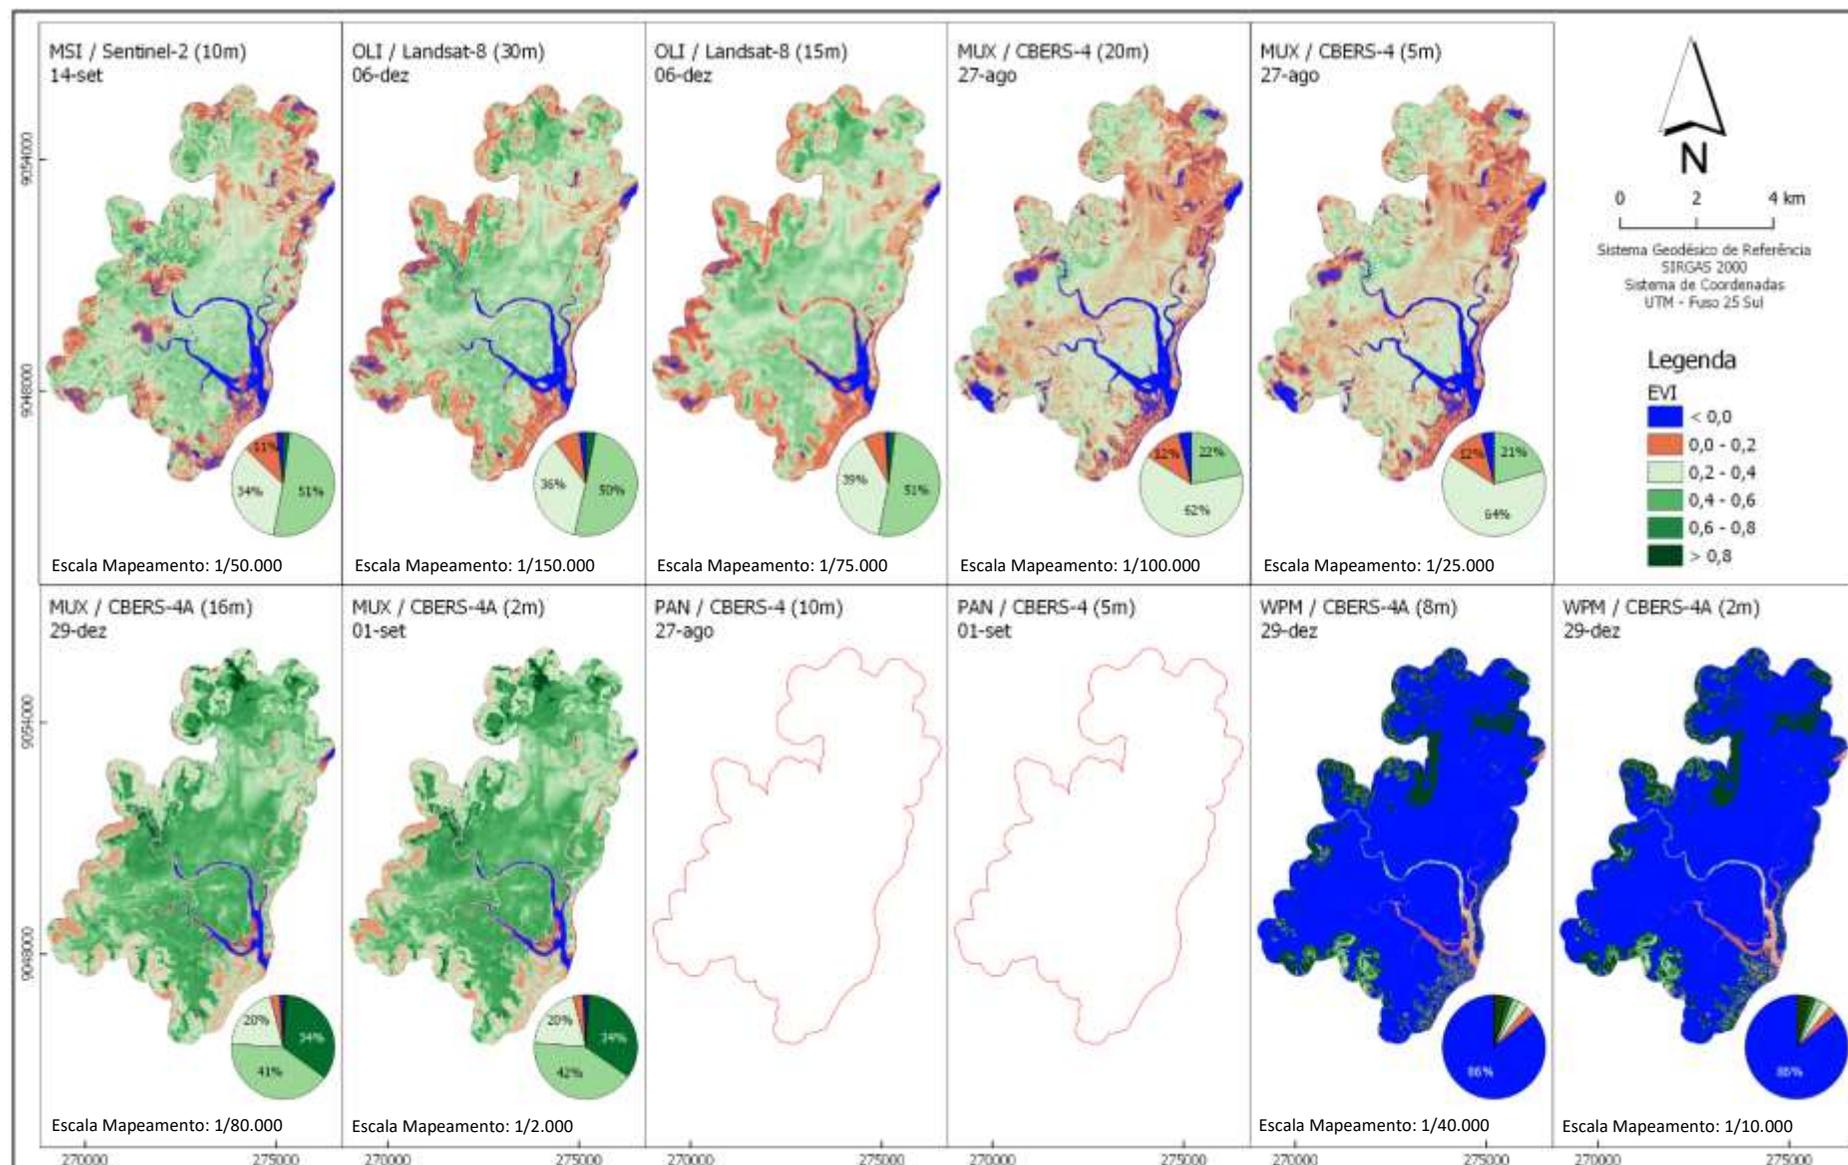
### 4.2.3 EVI - Enhanced Vegetation Index

Os resultados para o índice EVI (Figura 13) apresentaram um erro numérico para o sensor WPM (calculado a partir dos valores de ND da imagem). Do mesmo modo, esse índice também não é apresentado para o sensor PAN/CBERS-4, em virtude desse sensor não possuir a banda do espectro azul, necessária aos cálculos.

Os dados analisados nos mostram que os valores de vegetação encontrados com o índice EVI estão abaixo dos encontrados com o NDVI e similares aos encontrados com o índice SAVI. A classe intermediária é a de maior destaque em todos os produtos, com vegetação variando de 0,2 a 0,6 em mais de 60% dos pixels das imagens. O sensor MUX/CBERS-4A foi mais sensível a vegetação ao apresentar cerca de 30% dos pixels com vegetação entre 0,6 e 0,8 no índice EVI. Enquanto que o sensor MUX/CBERS-4 menos sensível, apresenta cerca de 75% dos pixels com valor de até 0,4 de índice EVI (vegetação pouco abundante).

O EVI foi desenvolvido para promover a redução das influências atmosféricas e do solo de fundo do dossel no monitoramento da vegetação. Também é caracterizado por continuar a apresentar resposta à vegetação abundante acima do nível em que o NDVI é capaz de responder (Justice *et. al.*, 1998 *apud* Laurentino, 2011). Todavia, no nosso estudo, nenhum dos índices analisados até agora, apresentaram saturação, nos levando a inferir que a vegetação presente na área de estudo, não demandam essa situação, talvez por ser o período sem chuvas na região que esteja sendo analisado nas imagens (setembro a dezembro). No estudo de Almeida (et al., 2008) em que ele aplica esse índice numa área de mata atlântica, observou-se uma forte relação de dependência entre o vigor da vegetação e pluviosidade, em que os valores de EVI se apresentaram maiores durante o período chuvoso.

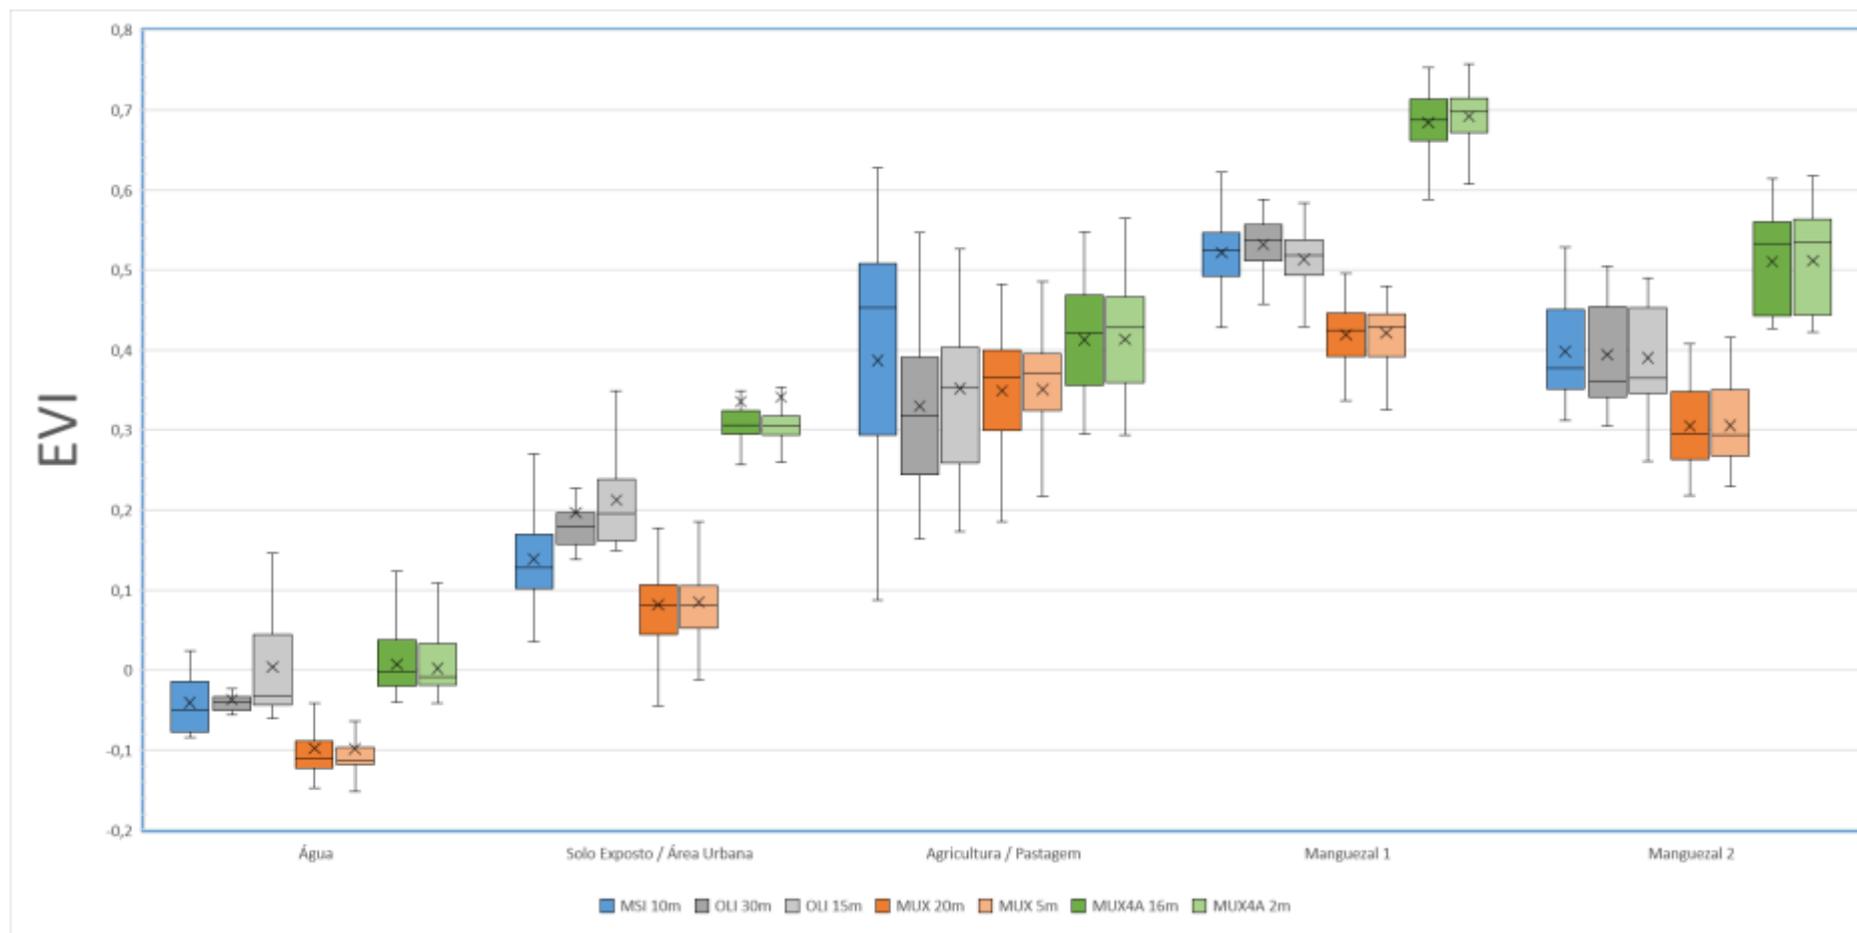
Figura 13 – Índice EVI do ano 2020



Fonte: o autor, 2022.

Também no Gráfico 4 com o *box plot* do EVI, ao modo dos dados do índice SAVI, não houve boa separabilidade entre os alvos solo exposto/área urbana, agricultura/pastagem e vegetação de mangue dos tipos 1 e 2. O sensor MUX, em todos os índices analisados até o momento, apresentou valores entre os mais baixos para a representação da vegetação de mangue. Como destaque positivo, temos o sensor MUX4A que conseguiu escalar os maiores valores de vegetação no EVI de maneira melhor que os demais sensores, melhorando a separabilidade entre as duas tipologias de mangue analisadas nesse estudo.

Gráfico 4 – Box plot do índice EVI, ano 2020



Fonte: o autor, 2022.

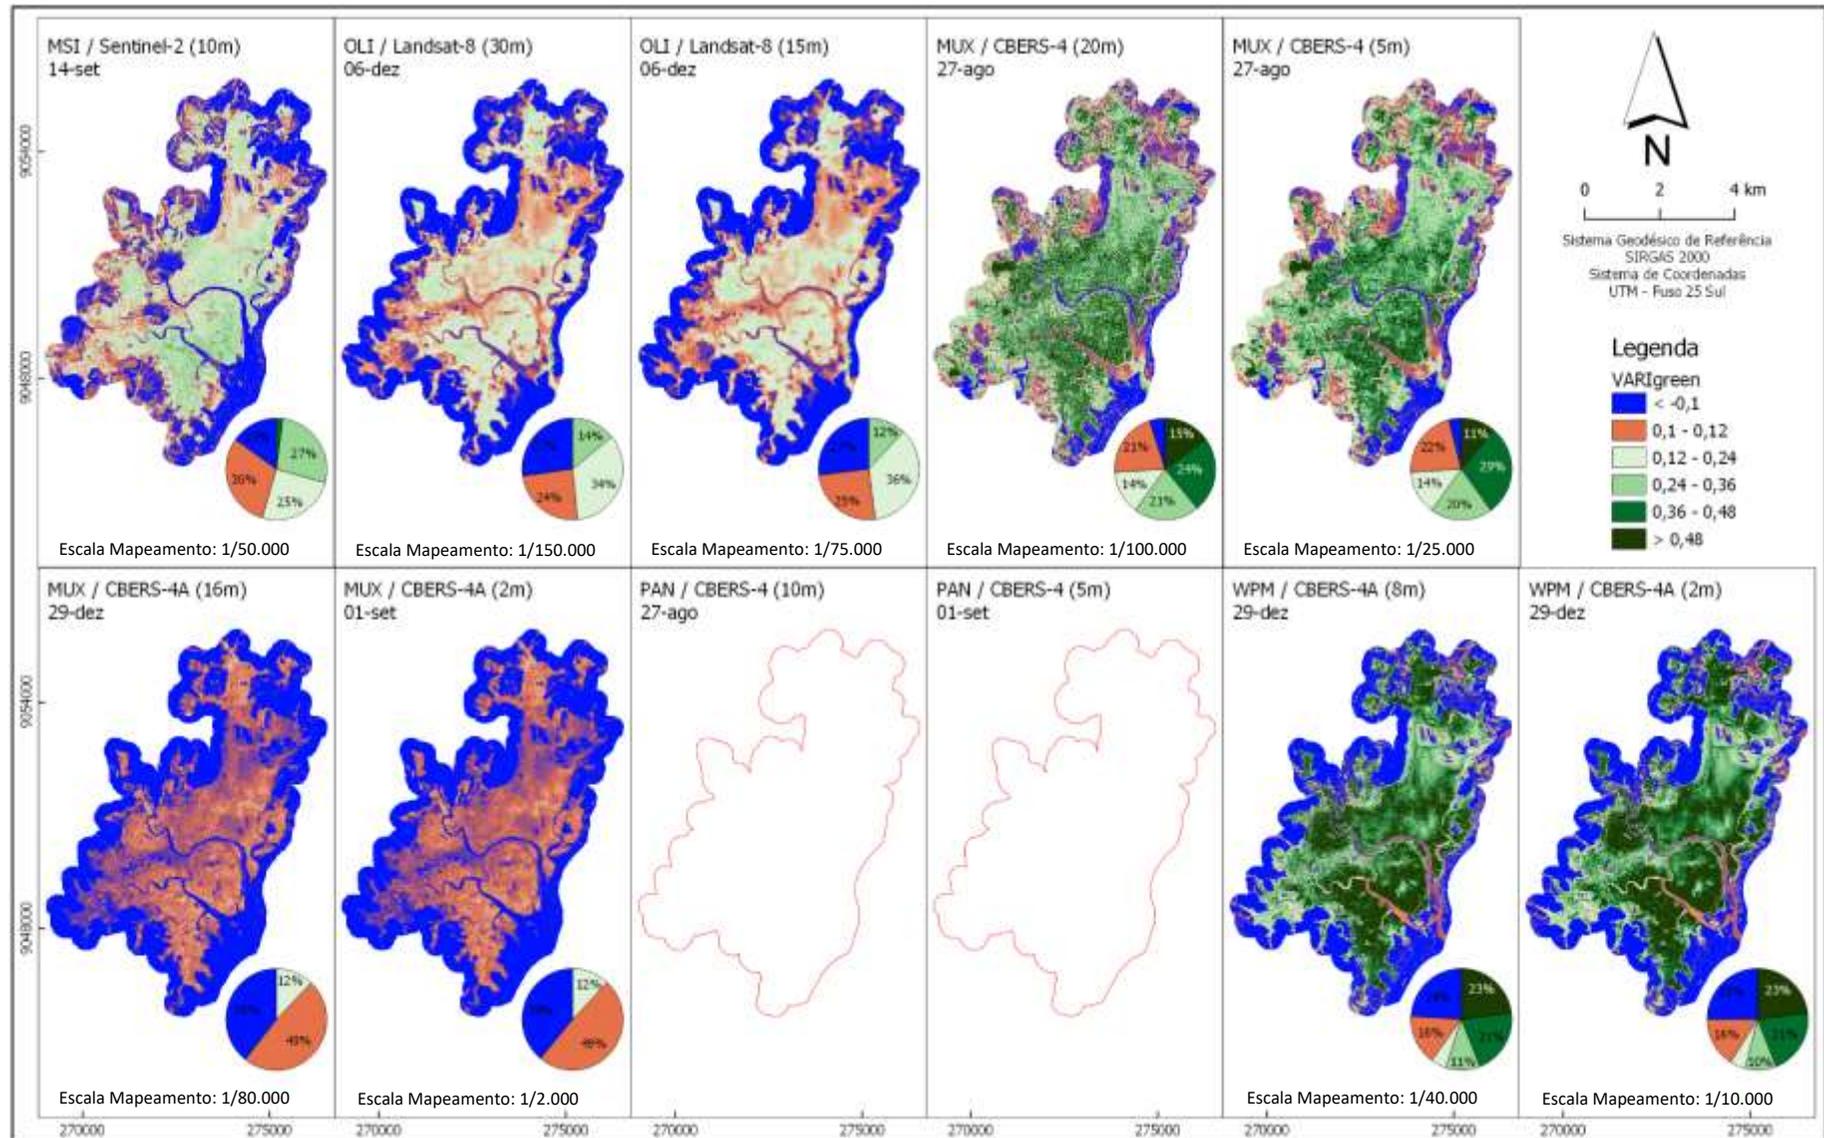
#### 4.2.4 VARIgreen – Visible Atmospherically Resistance Index

A alta absorção da REM pela vegetação na faixa espectral do visível, resulta em baixos valores de índice VARIgreen para a representação da vegetação presente na imagem. Esse fato é constatado na inspeção visual dos produtos gerados por todos os sensores do estudo. Novamente aqui, não há dados para o sensor PAN porque o mesmo não possui a faixa espectral do azul, necessária para a confecção desse índice.

O sensor MUX4A apresentou a vegetação em níveis extremamente baixos de índice VARIgreen, inviabilizando uma análise apurada no intervalo de classes estipulado na figura. O sensor MSI e OLI apresentaram quadros semelhantes entre si, da mesma forma que os sensores MUX e WPM. (ver Figura 14).

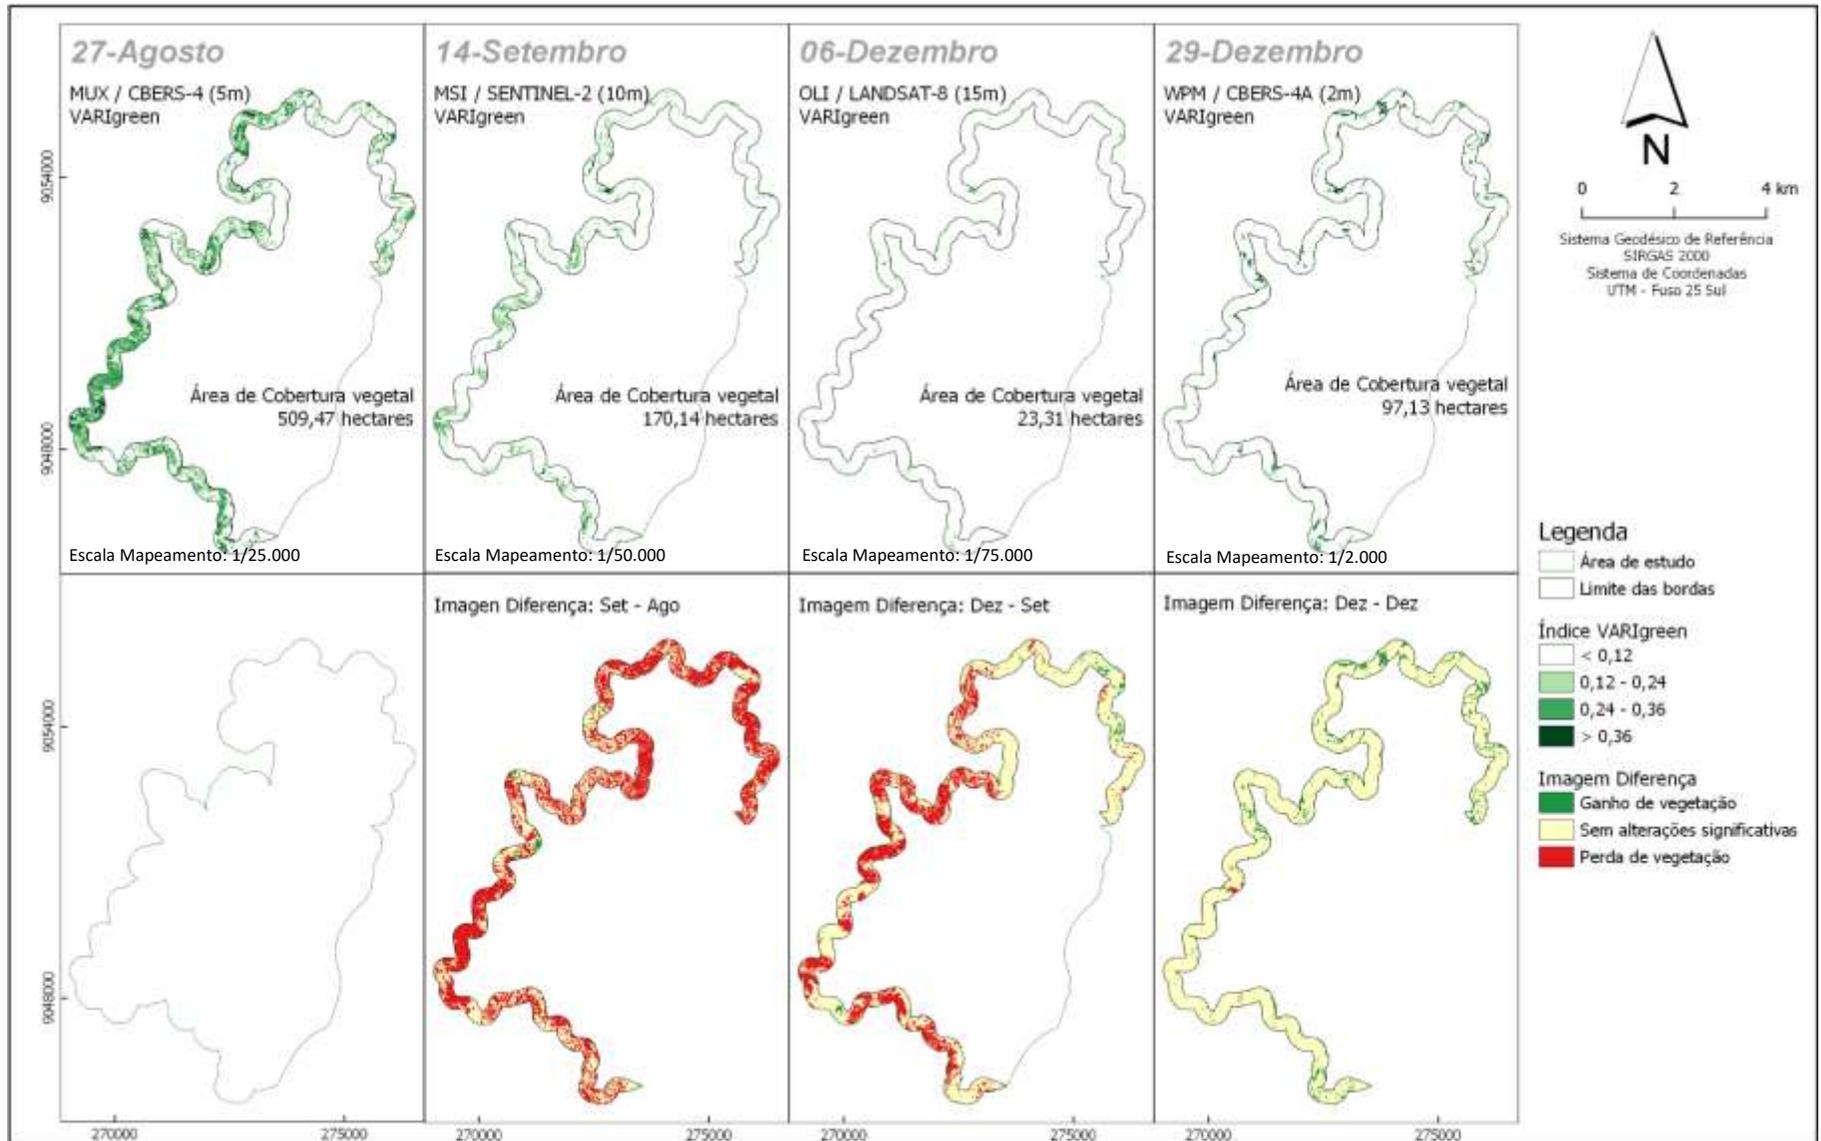
Como aspecto positivo, podemos citar que esse índice possibilitou um melhor delineamento acerca da sazonalidade das áreas de agricultura que circundam a vegetação de mangue na área de estudo. Na Figura 15 podemos visualizar uma análise mais apurada acerca das bordas da área nesse índice (considerando 300 metros em direção ao interior da área de estudo). Verificamos que na imagem MUX/CBERS-4, datada de 27 de agosto, a borda da área apresenta-se com quantidade expressiva de vegetação (509,47 hectares de cobertura vegetal), indicando que essas áreas ainda não haviam sido colhidas. Ao decorrer dos meses de setembro (imagem MSI/Sentinel-2, datada de 14 de setembro) até chegar em dezembro (imagem OLI – 06 de dezembro; imagem MUX4A e WPM – 29 de dezembro), temos a substituição dessas áreas pela classe de solo exposto/área urbana com a proporcional redução na cobertura vegetal nessas bordas (170,14 hectares em setembro, 23,31 hectares no início de dezembro e 97,13 hectares no final do mês de dezembro). A variação positiva encontrada entre as duas datas do mês de dezembro dá-se em virtude da melhor resolução espacial das imagens WPM/CBERS-4A com 2 metros, o que proporciona o mapeamento de pequenas manchas de vegetação impossíveis de serem detectadas com a resolução espacial de 15 metros da imagem fusionada do sensor OLI/LANDSAT-8 (ver figura 15).

Figura 14 – Índice VARIgreen do ano 2020



Fonte: o autor, 2022.

Figura 15 – Análise da sazonalidade da cobertura vegetal nas bordas da área de estudo a partir do índice VARIgreen

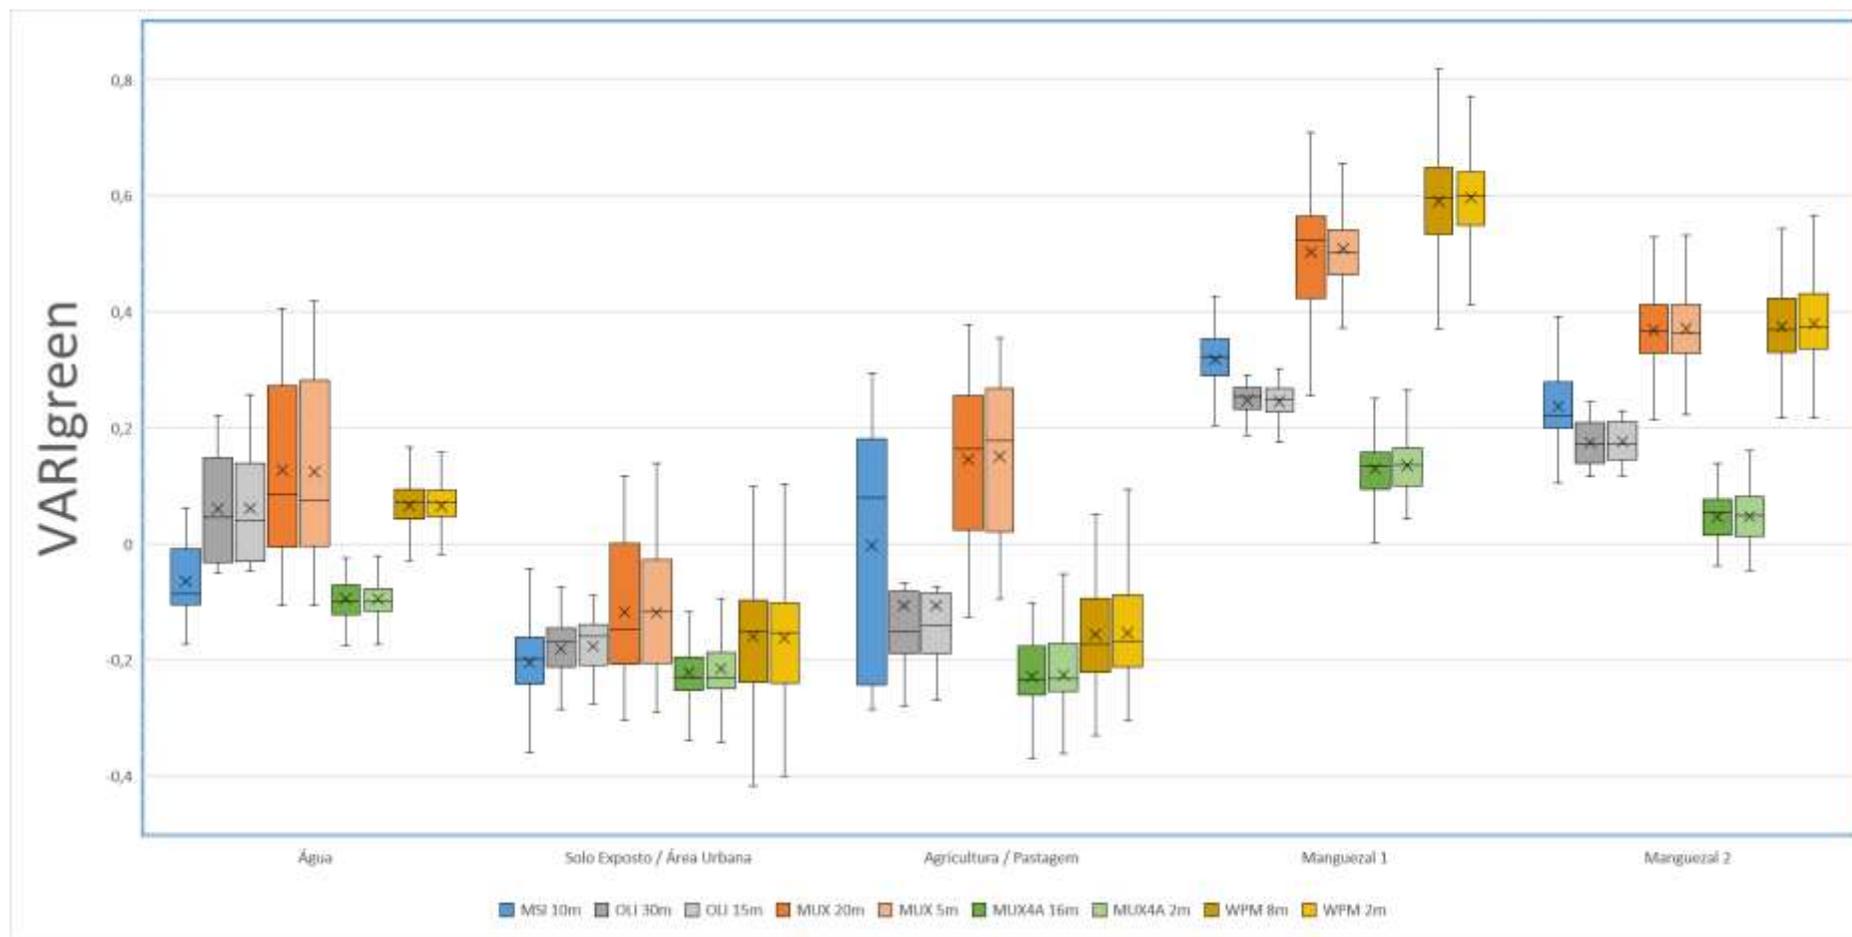


Fonte: o autor, 2022.

No Gráfico 5 abaixo apresentamos o *box plot* do índice VARIgreen para as amostras da área de estudo. No geral, o índice apresentou valores para os alvos água, solo exposto/área urbana e mangue tipos 1 e 2 coerentes com os demais índices avaliados até o momento. Também não há boa diferenciação entre as duas tipologias de mangue nesse índice.

Analisando especificamente o alvo Agricultura/Pastagem, apenas este índice foi capaz de apresentar significativa diferenciação entre os produtos dos sensores OLI/Landsat-8, MUX e WPM/CBERS-4A, cuja imagens foram obtidas em dezembro quando as culturas agrícolas já haviam sido retiradas e a terra já estava sendo preparada para a próxima cultura, e os dados do sensor MUX/CBERS-4, obtida no final de agosto, quando as culturas agrícolas ainda estavam presentes no solo. Isso tem impacto relevante na nossa pesquisa, porque significa que a melhor avaliação do quantitativo de cobertura vegetal de mangue da área de estudo se dá a partir das imagens obtidas no final do ano (mês de dezembro), pois do contrário, uma parte da cultura agrícola seria contabilizada como sendo vegetação de mangue.

Gráfico 5 – Box plot do índice VARIGreen, ano 2020



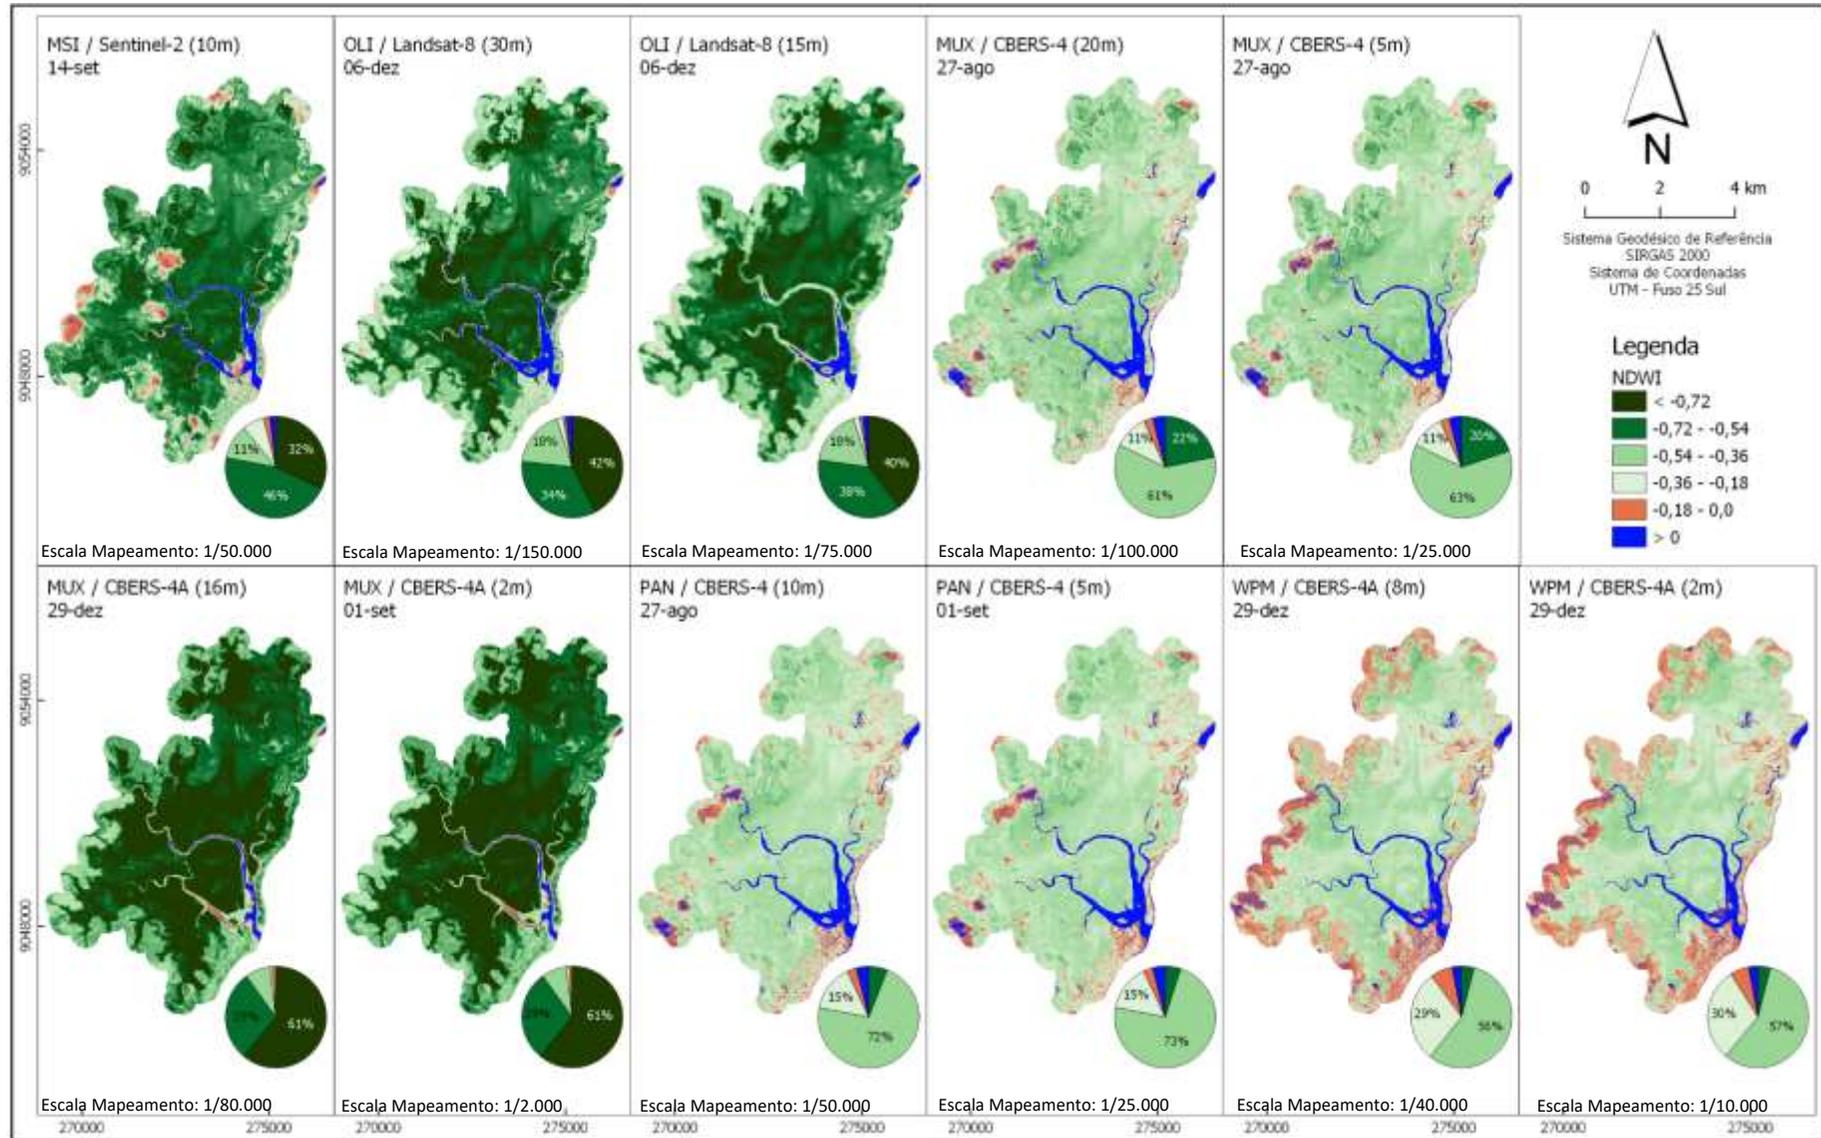
Fonte: o autor, 2022.

#### 4.2.5 NDWI – Normalized Difference Water Index

O último índice analisado foi o NDWI, que é próprio para realçar o conteúdo de água na vegetação. Nesse índice, os valores podem variar entre -1 e 1, as áreas com valores negativos indicam áreas com baixo teor de água, variando de acordo com o tipo de alvo capturado na imagem. Já os valores positivos indicam a presença de água.

Na Figura 16 que apresenta a espacialização do índice NDWI percebemos que os produtos MSI, OLI e MUX4A apresentaram resultados mais próximos entre si, indicando maior valores desse índice em toda a área pesquisada: cerca de 32%, 42% e 61% dos pixels, respectivamente, indicam NDWI maior que - 0,71. Os demais sensores apresentaram valores levemente inferiores, representando mais de 55% da cobertura vegetal da área com valores desse índice de até -0,54.

Figura 16 – Índice NDWI do ano 2020



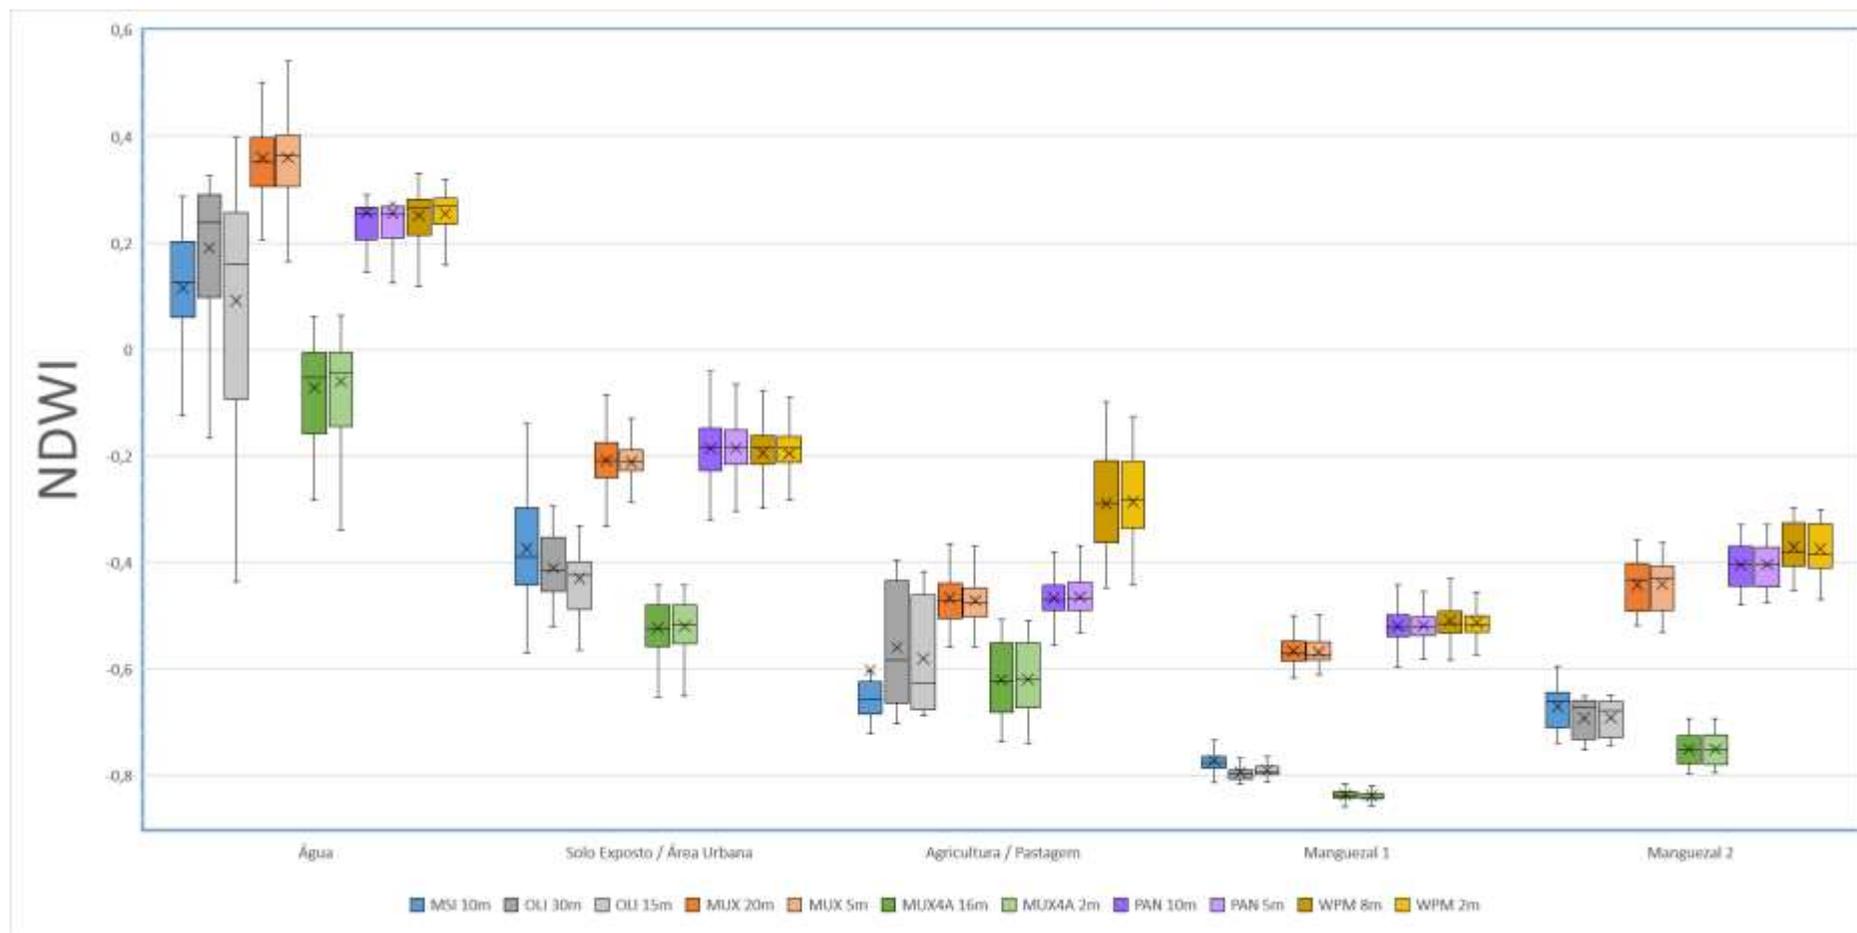
Fonte: o autor, 2022.

No Gráfico 6 que traz o *box plot* com os valores extraídos das amostras, observamos grande divergência nos valores encontrados para a vegetação entre os sensores MSI, OLI e MUX4A e os demais sensores, todavia, este índice também foi capaz de promover virtualmente a plena separação entre as duas tipologias de vegetação através dos sensores MSI, OLI e MUX4A.

Para todos os sensores, com exceção do MUX4A, os valores para o alvo água ficaram muito acima de 0. Isso pode ser resultado de um efeito *background* visto que na área em questão é possível visualizar, via imagens de alta resolução do Google Earth, muitos bancos de areia à vista. Por outro lado, a grande variabilidade nos dados do sensor OLI 15m pode ser um indicativo de que houve, de alguma forma, um deslocamento entre a imagem em resolução nativa e a imagem fusionada durante o processo de fusão, ocasionando uma espécie de contaminação de pixels de água das amostras com pixels das margens (vegetação e solo). Peter, Collischonn e Spironello (2013) já haviam alertado para esse fato em processos de fusão de imagens, onde erros de posicionamento acabam provocando distorções na resolução espectral.

Também notamos para os sensores MSI e OLI uma relativa dificuldade nesse índice em relação a diferenciação dos alvos água e solo exposto / área urbana, conforme observação de Pereira (*et al.*, 2018), mas esse fato não se repetiu para os demais sensores.

Gráfico 6 – Box plot do índice NDWI, ano 2020



Fonte: o autor, 2022.

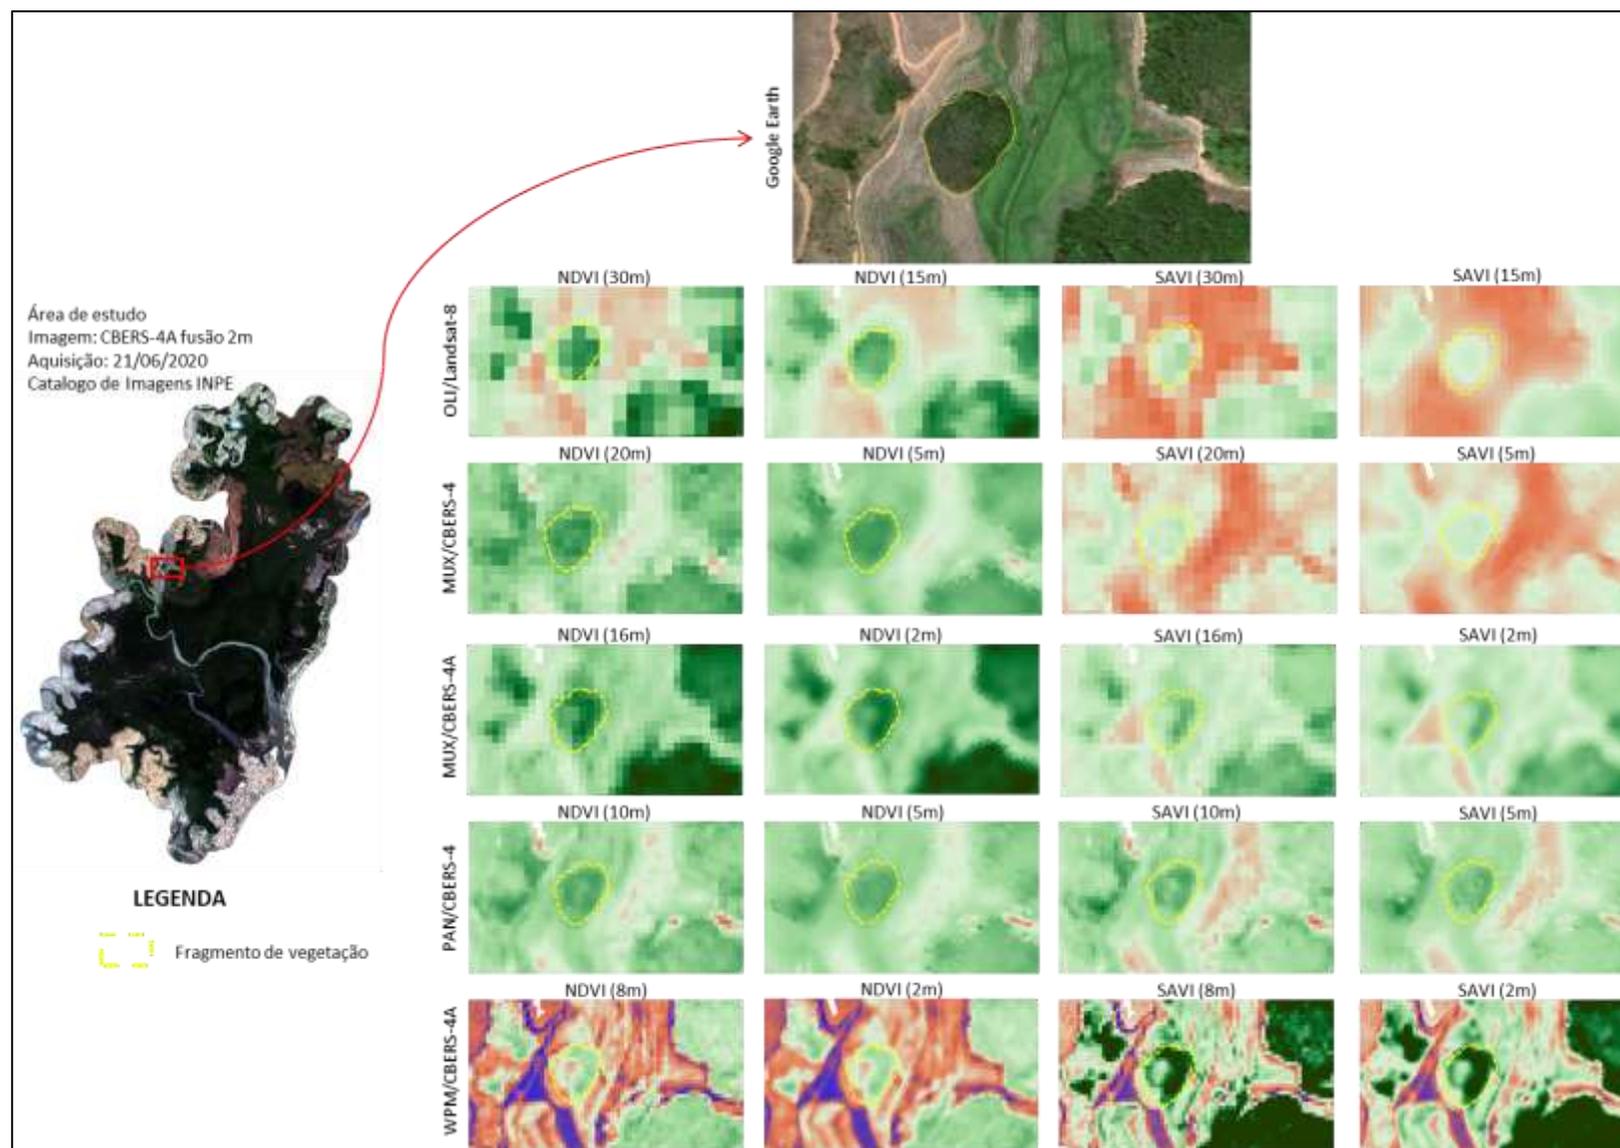
No geral, podemos afirmar que mesmo a análise com os valores estatísticos extraídos das imagens e apresentados na Tabela 4 não ter evidenciado diferenças significativas, há claramente uma aproximação nos resultados obtidos entre os sensores OLI e MSI quando comparados com os demais. Em comum, esses dois sensores possuem, na banda do vermelho, uma calibração com valores semelhantes, tanto nos comprimentos de onda limítrofes como na largura de banda ( $0,3 \mu\text{m}$ ). Nos demais sensores, a largura de banda no vermelho é o dobro ( $0,6 \mu\text{m}$ ).

#### **4.2.6 Índices Fusionados**

Nas Figuras 17 e 18, podemos visualizar alguns recortes para detalhamento do efeito obtido a partir da fusão das imagens nos índices NDVI e SAVI. Como era esperado, observa-se expressivo melhoramento do contorno visual das feições, com apresentação de bordas e contornos mais suaves e melhor definidos. Isso proporciona facilidade para as atividades técnicas que demandem interpretação visual da imagem, como mapeamento temáticos, medições de áreas, dentre outras. Todavia, ressalta-se que a despeito dos índices terem sido gerados com uma resolução espacial melhor que a nativa, não apresentam informações adicionais além daquelas já aparentes nos índices em resolução nativa, ou seja, mesmo fusionadas, as imagens não permitem a visualização de pequenas áreas ocultas de desmatamento ou corpos hídricos, só notadas em imagens de melhor resolução espacial.

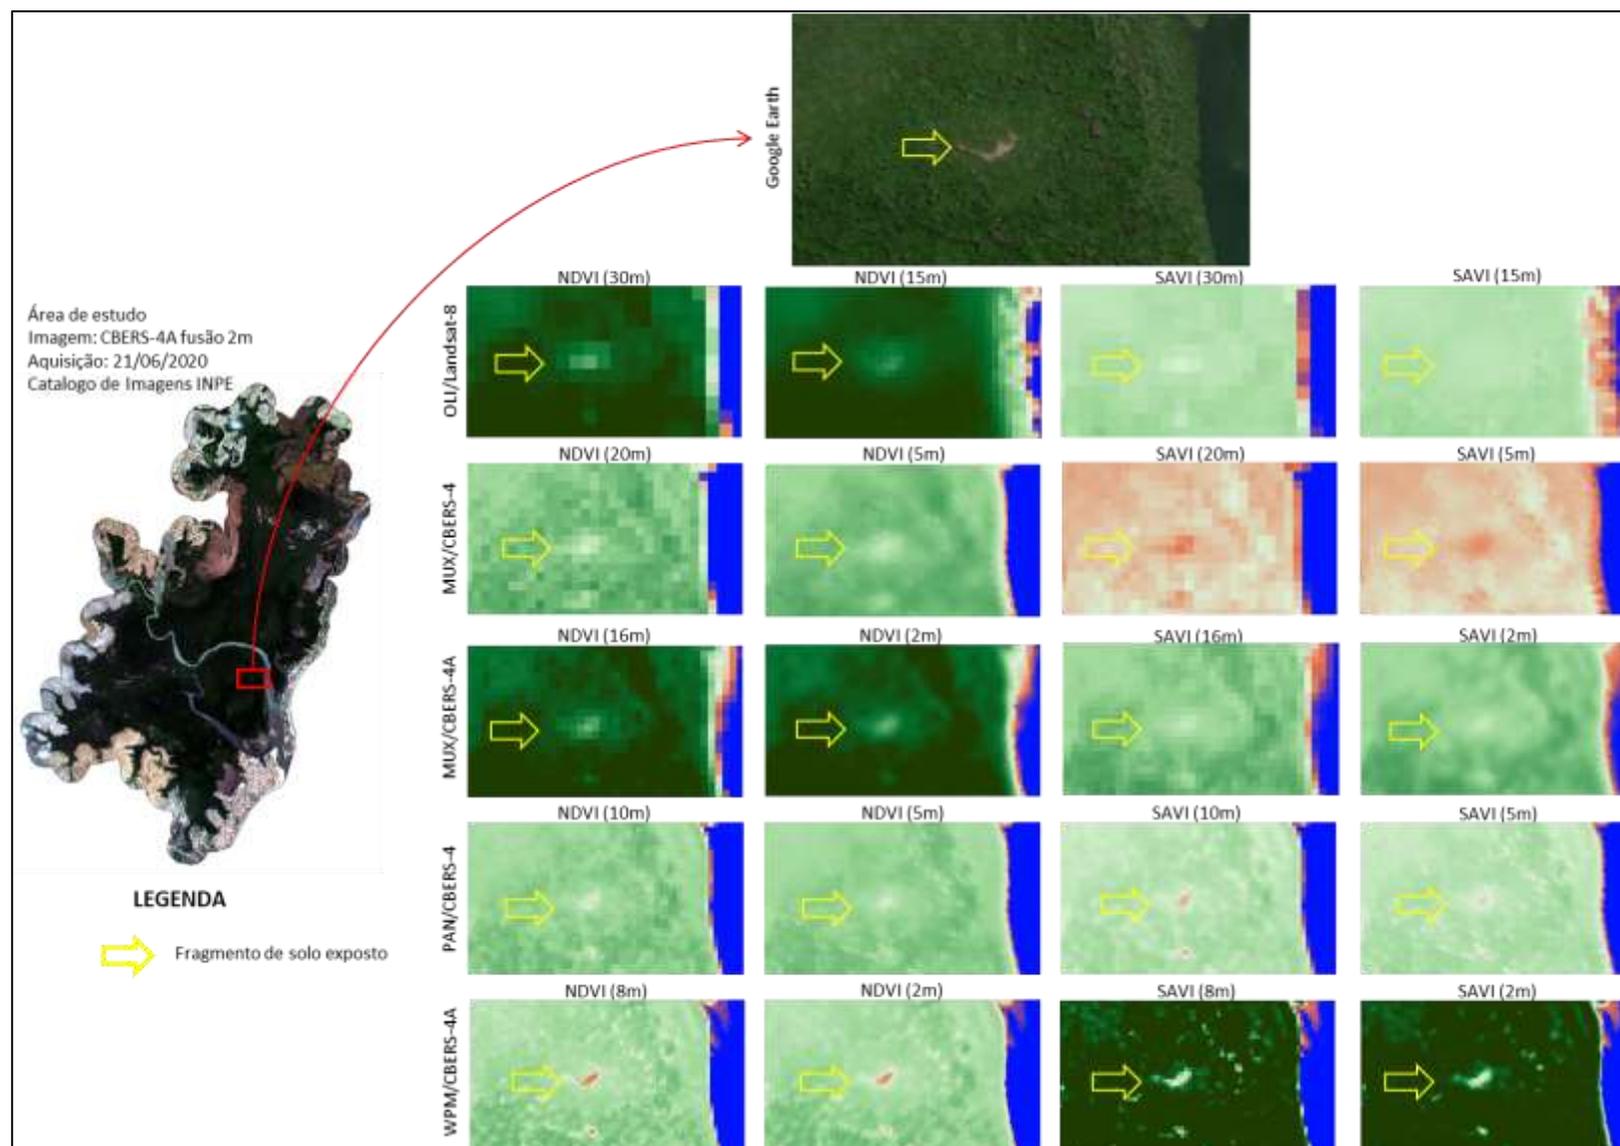
Além da resolução espacial, também merece destaque o fato de que a alta resolução radiométrica das imagens OLI (16 bits) parece afetar positivamente neste quesito, visto que mesmo com a menor resolução espacial dentre todos os sensores, os detalhes mostrados nas Figuras 17 e 18 não passaram despercebidos por este sensor. Esta observação é compatível com as conclusões de Benvindo e Rocha (2020) que observaram que as imagens OLI mantêm a qualidade radiométrica após o processo de fusão.

Figura 17 – Fragmento de vegetação em meio a solo exposto



Fonte: o autor, 2022.

Figura 18 – Pequeno fragmento de solo exposto em meio a vegetação



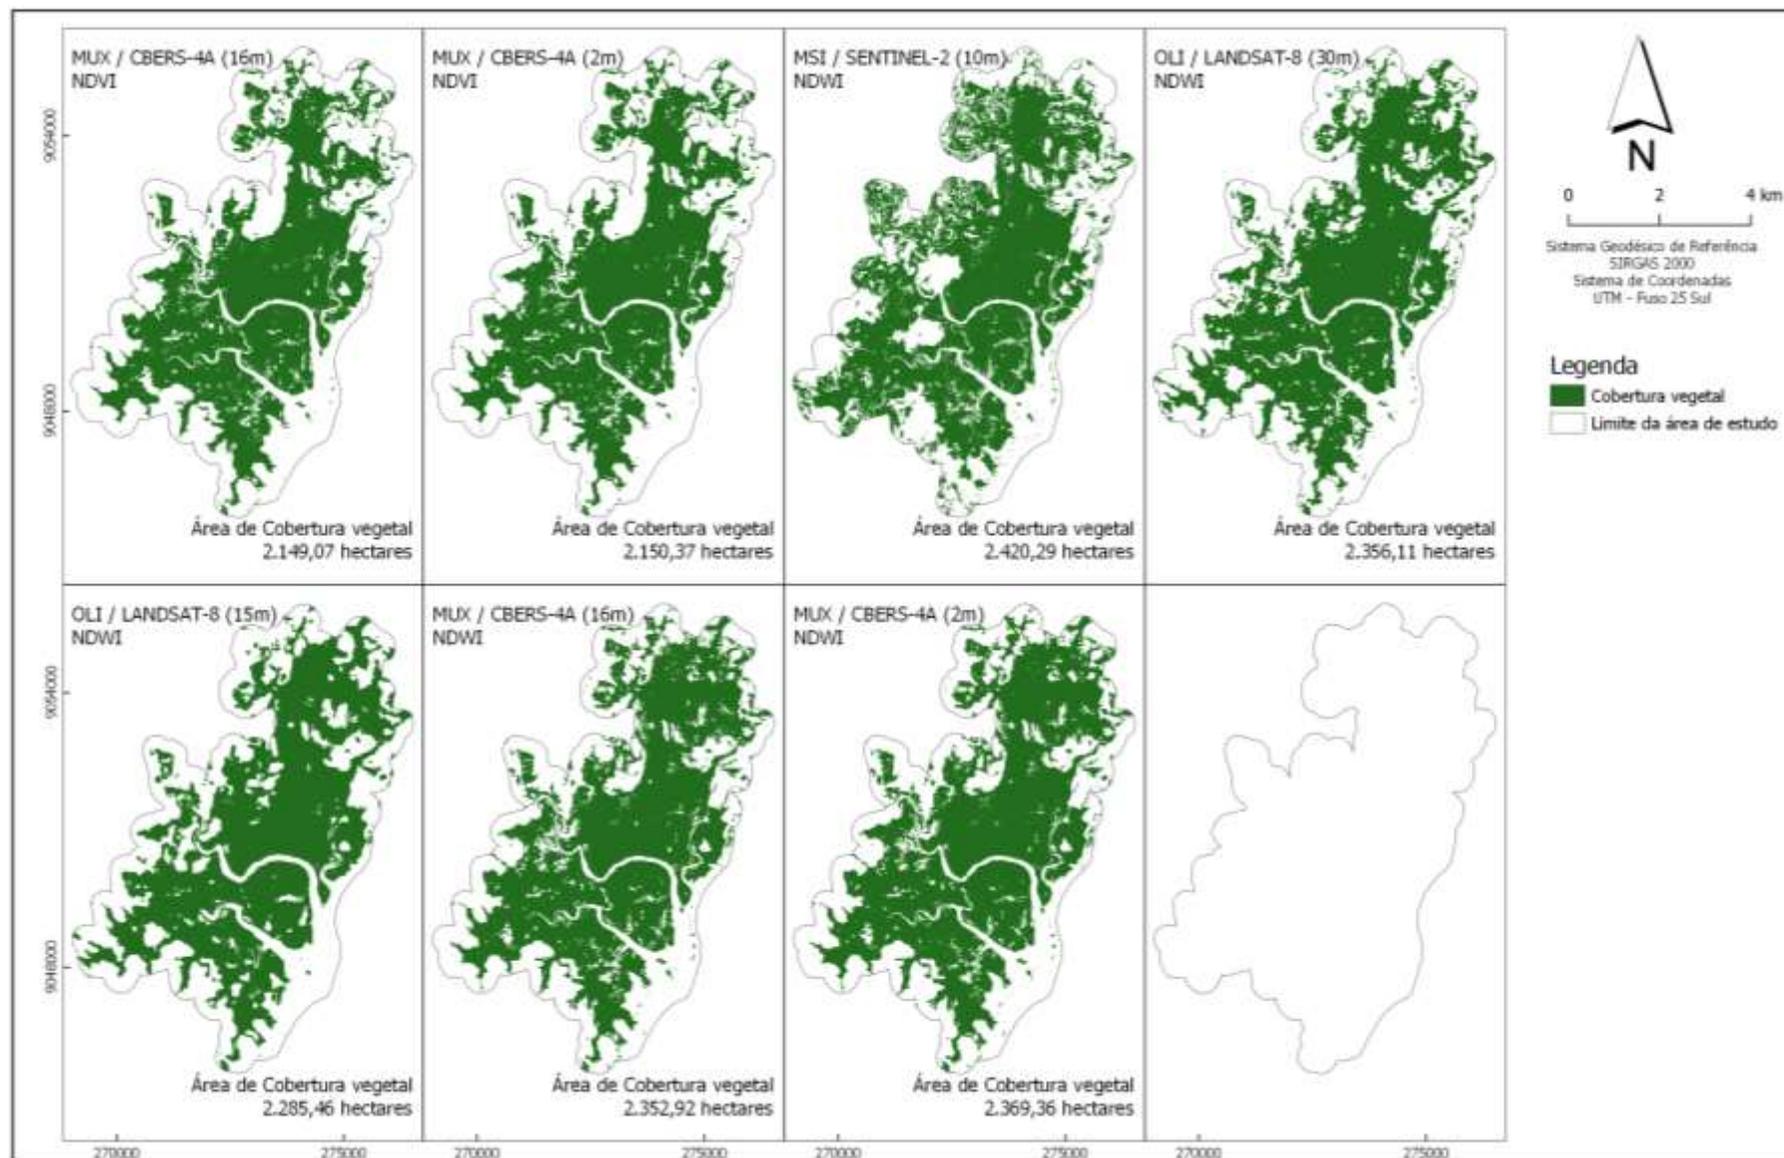
Fonte: o autor, 2022.

#### 4.3 MAPEAMENTO DA COBERTURA VEGETAL NO ANO 2020

Partindo-se então dos resultados obtidos com a análise dos gráficos, selecionamos os melhores índices, ou seja, selecionamos aqueles índices que promoveram a melhor separação entre os alvos de vegetação de mangue e os demais, para por meio do processo de fatiamento dos histogramas, gerarmos um mapa com a cobertura vegetal da área de estudo. Também apresentamos um mapeamento dentre as duas tipologias de vegetação de mangue abordados nesse estudo.

Os índices selecionados para o ano de 2020 foram: NDVI (sensor MUX4A) e NDWI (sensores MSI, OLI e MUX4A). As representações desses mapeamentos são apresentadas na Figura 19 abaixo, enquanto que as áreas de cobertura vegetal encontradas estão sintetizadas na Tabela 5.

Figura 19 – Mapeamento da cobertura vegetal, ano 2020



Fonte: o autor, 2022.

Tabela 5 – Quantitativo de cobertura vegetal para o ano de 2020

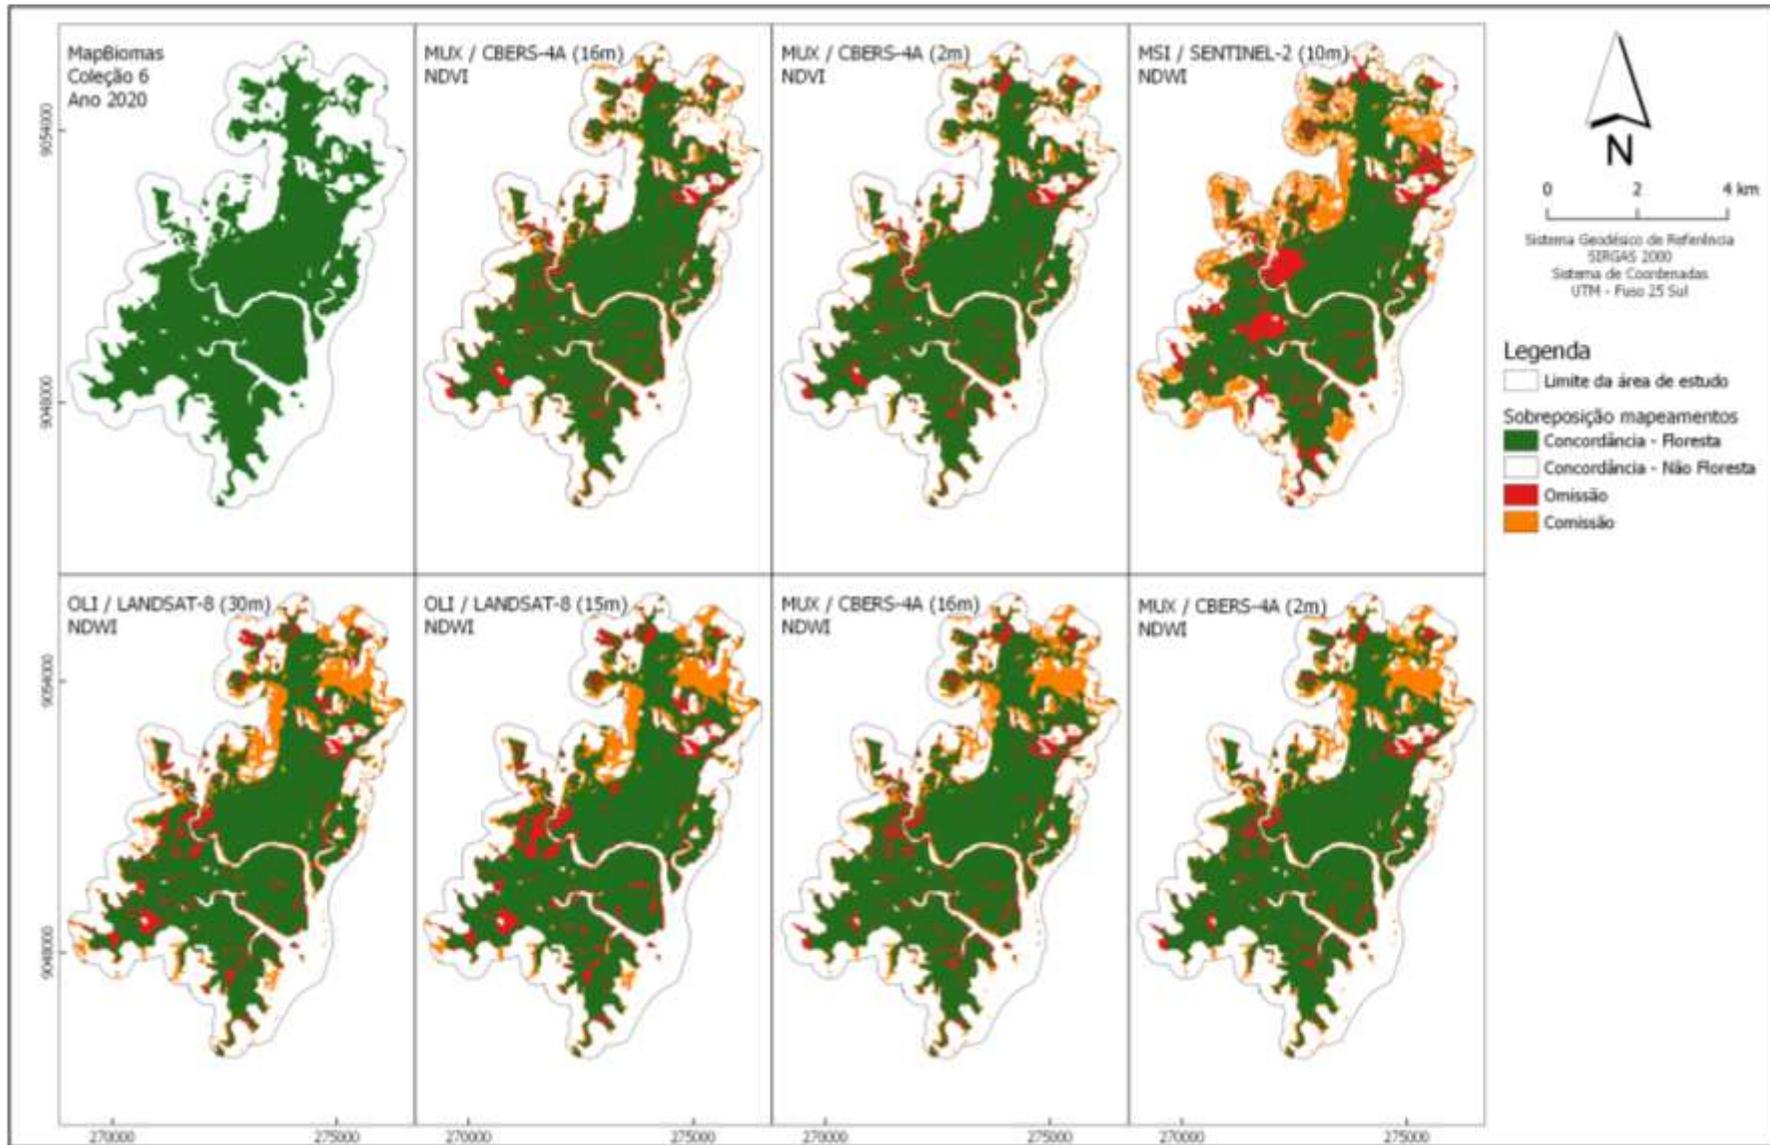
Índice	Sensor	Resolução Espacial	Área (ha)
NDVI	MUX/CBERS-4A	16 m	2.149,07
NDVI	MUX/CBERS-4A	2 m	2.150,37
NDWI	OLI/LANDSAT-8	15 m	2.285,46
NDWI	MUX/CBERS-4A	16 m	2.352,92
NDWI	OLI/LANDSAT-8	30 m	2.356,11
NDWI	MUX/CBERS-4A	2 m	2.369,36
NDWI	MSI/SENTINEL-2	10 m	2.420,29

Fonte: o autor, 2022.

O menor valor encontrado foi 2.149,07 hectares através do índice NDVI do sensor MUX/CBERS-4A e o maior foi 2.420,29 hectares por meio do índice NDWI do sensor MSI/Sentinel-2, importando, portanto, uma variação de 11,21%.

Posteriormente, os resultados foram sobrepostos ao mapeamento realizado pelo Projeto MapBiomias, Coleção 6, ano 2020, afim de comparação de área e também para verificarmos eventuais diferenças. Para o MapBiomias, a cobertura vegetal na área é de 2.216,65 hectares. Essa análise de concordância de mapeamento pode ser visualizada na Figura 20 a seguir.

Figura 20 – Concordância de mapeamento com o projeto MapBiomias 2020



Fonte: o autor, 2022.

Uma análise de concordância espacial entre os mapeamentos resultantes desta pesquisa e o mapeamento do MapBiomas, revelou que em média, há uma concordância das áreas de mangue de 46,54% e das áreas sem floresta de mangue de 36,32%. Resultando numa concordância geral de 82,44%, em média. A menor concordância geral (70,61%) foi encontrada no mapeamento com o índice NDWI com dados MSI/Sentinel-2, e a maior concordância (88,39%), foi encontrado utilizando-se o índice NDVI com dados MUX/CBERS-4A. O erro de comissão, ou seja, quando contabilizamos floresta de mangue sem a confirmação no mapeamento do MapBiomas, foi, em média, de 9,44%. E o erro de Omissão, quando deixamos de contabilizar floresta de mangue, foi de 7,39%, em média. Os dados completos de concordância podem ser visualizados na Tabela 6 abaixo:

Tabela 6 – Dados de concordância espacial da área de estudo com o projeto MapBiomas

Sensor Resolução Índice	Mangue nos dois mapeamentos (hectares)	Não Mangue nos dois mapeamentos (hectares)	% de concordância geral com o MapBiomas	% de erro de comissão com o MapBiomas	% de erro de omissão com o MapBiomas
MUX4A 16m NDVI	1933,29	1655,19	87,37	5,64	6,91
MUX4A 2m NDVI	1952,10	1678,89	88,39	5,11	6,43
MSI 10m NDWI	1781,27	1242,69	70,61	15,45	10,55
OLI 30m NDWI	1912,59	1438,83	81,57	10,75	7,37
OLI 15m NDWI	1882,96	1478,95	81,84	9,74	8,11
MUX4A 16m NDWI	1946,70	1465,96	83,08	9,85	6,58
MUX4A 2m NDWI	1976,28	1485,88	84,28	9,54	5,84

Fonte: o autor, 2022.

O maior erro de comissão encontrado na análise do mapeamento com imagens MSI/Sentinel-2 está relacionado ao período de obtenção da imagem, que é num período anterior a colheita das áreas agrícolas no entorno da área. Dessa forma, o índice foi eficiente para a separação da vegetação de outros alvos (solo exposto e corpo hídrico), mas falhou na diferenciação correta entre áreas de cultivo agrícola e a floresta de mangue.

#### 4.4 MAPEAMENTO DA COBERTURA VEGETAL NOS ANOS DE 2000 E 2010

A cobertura vegetal da área de estudo também foi avaliada em mais dois momentos distintos, no ano 2000 e no ano de 2010, perfazendo assim um intervalo de vinte anos e com isso poderemos avaliar a evolução dessa cobertura vegetal ao longo do tempo e eventualmente identificar possíveis áreas de supressão de vegetação e expansão da ocupação urbana.

Para esses anos utilizamos apenas imagens do sensor *Thematic Mapper* (TM) a bordo do satélite Landsat 5. Infelizmente, não há imagens disponíveis dos satélites brasileiros para esses anos em específico. Imagens do satélite CBERS 1 não estão disponíveis no catálogo de imagens do INPE, e tendo o satélite CBERS 2, lançado em outubro de 2003, funcionando até início do ano 2009 e o satélite CBERS 2B, lançado em 2007, deixando de funcionar no início do ano 2010. A escolha do ano de 2010 para esse mapeamento intermediário se faz necessária por conta da necessidade de comparação dos resultados obtidos com mapeamentos previamente realizados na área. Os dados obtidos nesse ano foram comparados com o trabalho de (SILVA, 2012).

No Quadro 6 abaixo apresentamos as principais informações do sensor utilizado nos anos 2000 e 2010.

Quadro 6 – Principais características do sensor utilizado

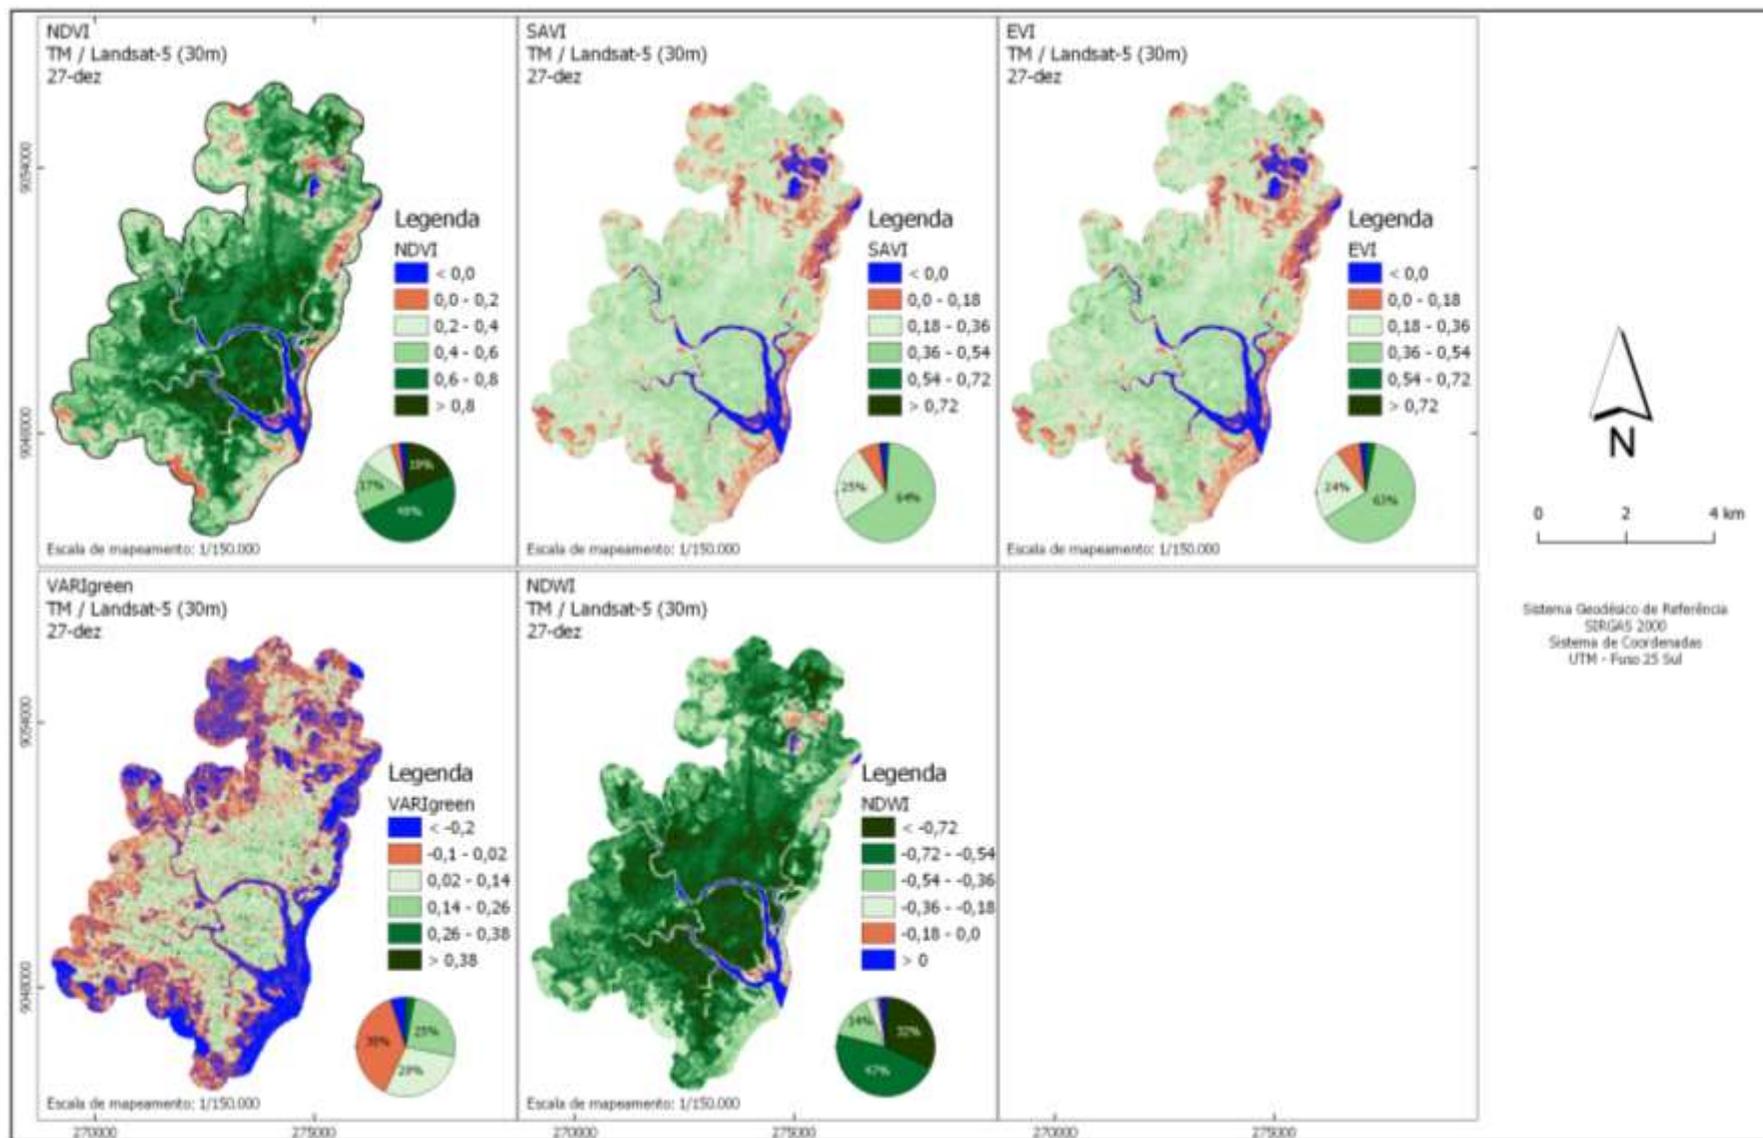
Sensor/Satélite	TM/Landsat-5
Data das Imagens	12/10/2000 27/12/2010
Bandas espectrais ( $\mu\text{m}$ )	B1(Azul): 0,45 – 0,52
	B2(Verde): 0,52 – 0,60
	B3(Vermelho): 0,63 – 0,69
	B4(NIR): 0,76 – 0,90
Campo de visada	185 km
Resolução espacial	30 m
Resolução radiométrica	8 bits
Periodicidade	16 dias

Fonte: o autor, 2022.

##### 4.4.1 Análise dos índices

Na Figura 21 que segue, assim como nas análises anteriores, fizemos a espacialização dos valores encontrados em cada índice calculado para o ano de 2000, bem como a quantificação a partir de cada intervalo de valores.

Figura 21 – Espacialização dos valores dos índices NDVI, SAVI, EVI, VARIGreen e NDWI para o ano de 2000



Fonte: o autor, 2022.

Os dados dos índices NDVI e NDWI apresentaram os maiores valores representativos de vegetação com alta densidade de biomassa. Cerca de 68% da cobertura vegetal foi classificada como maior que 0,6 no índice NDVI, e 79% categorizada como maior que -0,54 no índice NDWI, o que equivale a uma vegetação de elevado vigor vegetativo. Mesmo assim, esses valores são menores que os encontrados para o ano de 2020 para os mesmos índices.

Os índices SAVI e EVI apresentam um panorama quase idêntico ao do ano de 2020, onde os dois índices apresentam valores semelhantes entre si e menores que o índice do NDVI. A categoria de destaque é a intermediária, entre 0,36 e 0,54, isso significa que mesmo as áreas com maior abundância de biomassa não alcançaram valores significativos nesses índices o que os coloca próximos, na escala do índice, de áreas com média densidade e mesmo as de baixa densidade. Isso dificulta a discriminação da cobertura vegetal e provavelmente refletirá na qualidade dos produtos para mapeamento gerados a partir desses índices.

O índice VARIgreen representou a cobertura vegetal com os menores valores entre todos os índices, cerca de 54% dos pixels com até 0,36 na escala do índice. Dessa maneira, não há uma boa separabilidade entre os alvos na imagem. Podemos verificar que os alvos: solo exposto, solo urbano e água, por exemplo, foram aglutinados numa mesma categoria, o que inviabiliza uma rápida solução para o mapeamento de uso do solo usando esse produto.

No Gráfico 7 a seguir, apresentamos através de *box plot* os valores extraídos de amostras de cinco diferentes classes de uso e cobertura do solo nas imagens índices do ano 2000: água, solo exposto/ área urbana, agricultura / pastagem, manguezal tipo 1 e manguezal tipo 2. Cada cor representa um índice calculado. Observamos que os índices SAVI e EVI apresentam valores idênticos para todos os alvos pesquisados. Estes índices conseguem fazer boa separação entre o alvo água e mangue do tipo 1 para os demais alvos, mas apresenta grande sobreposição entre os alvos solo exposto/ área urbana, agricultura/ pastagem e mangue do tipo 2.

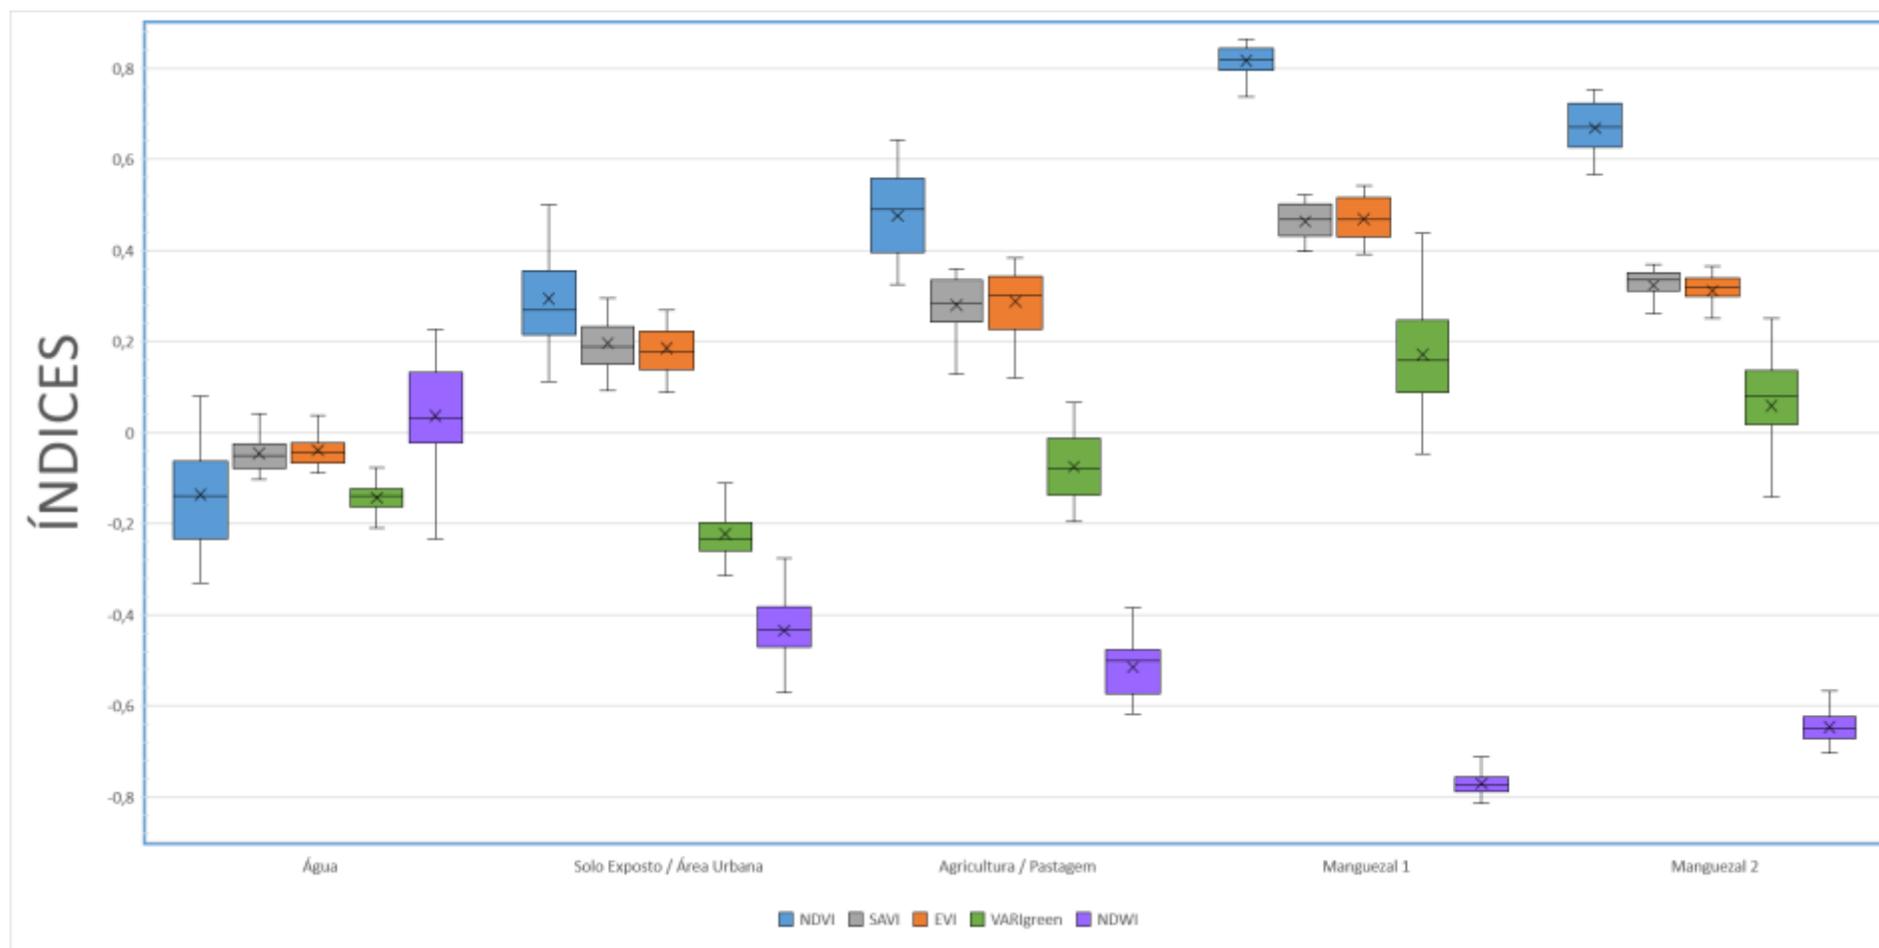
O índice VARIgreen não conseguiu um bom desempenho em termos de separabilidade entre os alvos avaliados, o que inviabiliza sua utilização. Apesar disso, se tentarmos numa perspectiva simplista em que desejássemos apenas separar duas categorias: vegetação e não-vegetação e conseguir assim o limite das áreas de vegetação, talvez o emprego desse índice possa ser melhor avaliado.

Em termos gerais, os índices NDVI e NDWI saíram-se melhores que os demais pelos seguintes motivos:

- a) conseguiram fazer relativamente bem a separação entre todos os alvos;
- b) apresentaram maior sensibilidade à vegetação de maior vigor vegetativo; e principalmente,

c) apresentaram sobreposição mínima entre as classes agricultura/ pastagem e manguezal do tipo 2.

Gráfico 7 – Box plot dos índices NDVI, SAVI, EVI, VARIGreen e NDWI, ano 2000



Fonte: o autor, 2022.

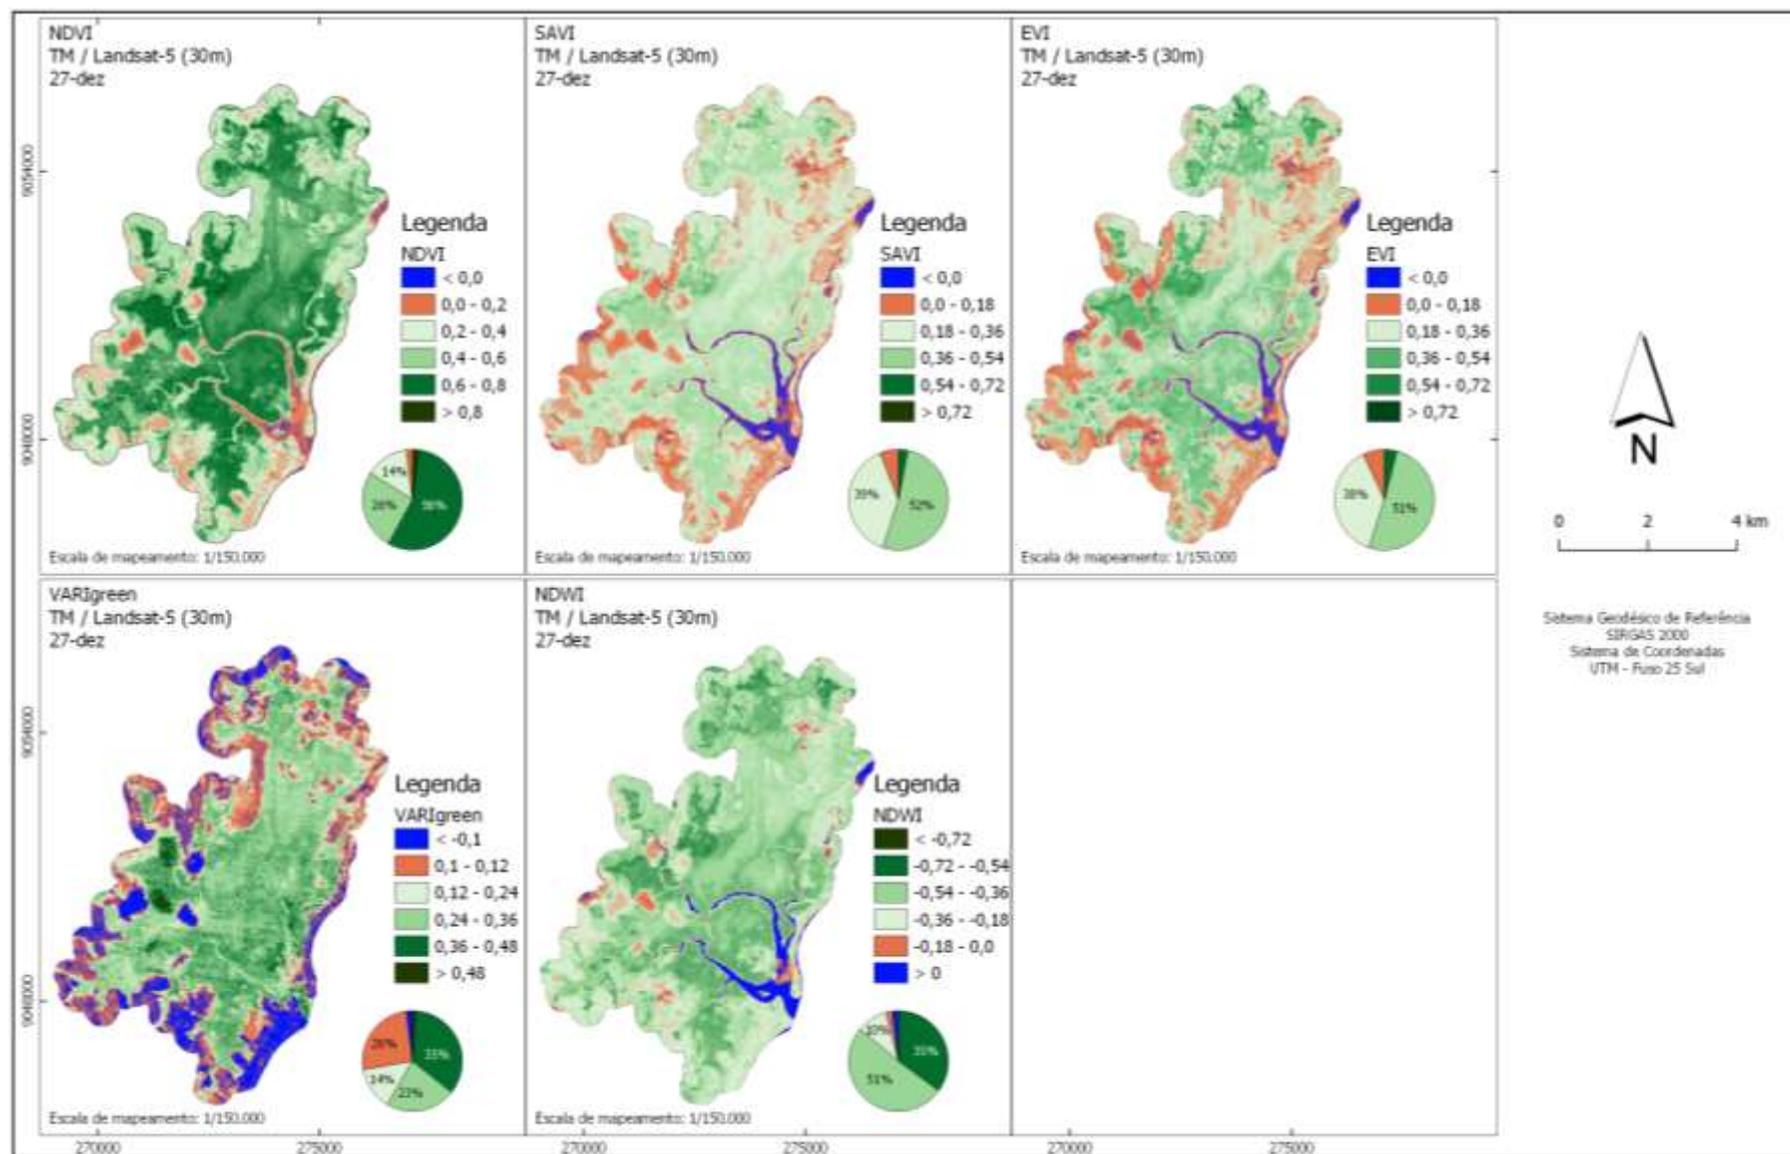
Já os dados do ano de 2010 são apresentados na Figura 22. O índice NDVI evidenciou que cerca de 56% dos pixels apresentaram valores superiores 0,60, o que equivale a uma vegetação de biomassa relativamente abundante. Todavia, esse valor para a representação das áreas de maior abundância de biomassa na área é levemente inferior ao encontrado nos anos 2000 e 2020 para o sensor OLI do satélite Landsat-8. No geral, a vegetação de mangue está bem realçada na representação e as áreas de agricultura e pastagens nas bordas da área, apresenta duas situações: uma de solo exposto representada em tons de laranja e que nós traduzimos em áreas foram recentemente colhidas; e algumas partes apresentando uma vegetação mais rala representada em tons suaves de verde claro (NDVI em torno de 0,3) e que nós traduzimos com a ajuda das imagens de alta resolução do Google Earth como sendo de pastagens.

Os resultados encontrados para os índices SAVI e EVI, novamente, são semelhantes entre si e com valores inferiores aos encontrados no NDVI. Nesses dois índices, a classe intermediária é a de maior destaque, com valores variando entre 0,36 e 0,54 em mais de 50% dos pixels. Em ambas representações os corpos hídricos foram bem delineados, mas as áreas de solo exposto / Área urbana foram superdimensionadas.

A espacialização dos dados do índice VARIGreen apresenta grande confusão entre as áreas de corpos hídricos, solo exposto e área urbana fazendo com que o mapa apresente apenas dois alvos distintos, vegetação e não vegetação. Essa simplificação é útil para avaliarmos as bordas da imagem e fazermos a separação entre vegetação de mangue e os demais alvos.

Por fim, o índice NDWI apresentou boa sensibilidade a vegetação da área apresentado valores superiores a -0,54 em 35% dos pixels. Mas assim como nos índices SAVI e EVI, a classe intermediária é a de maior destaque.

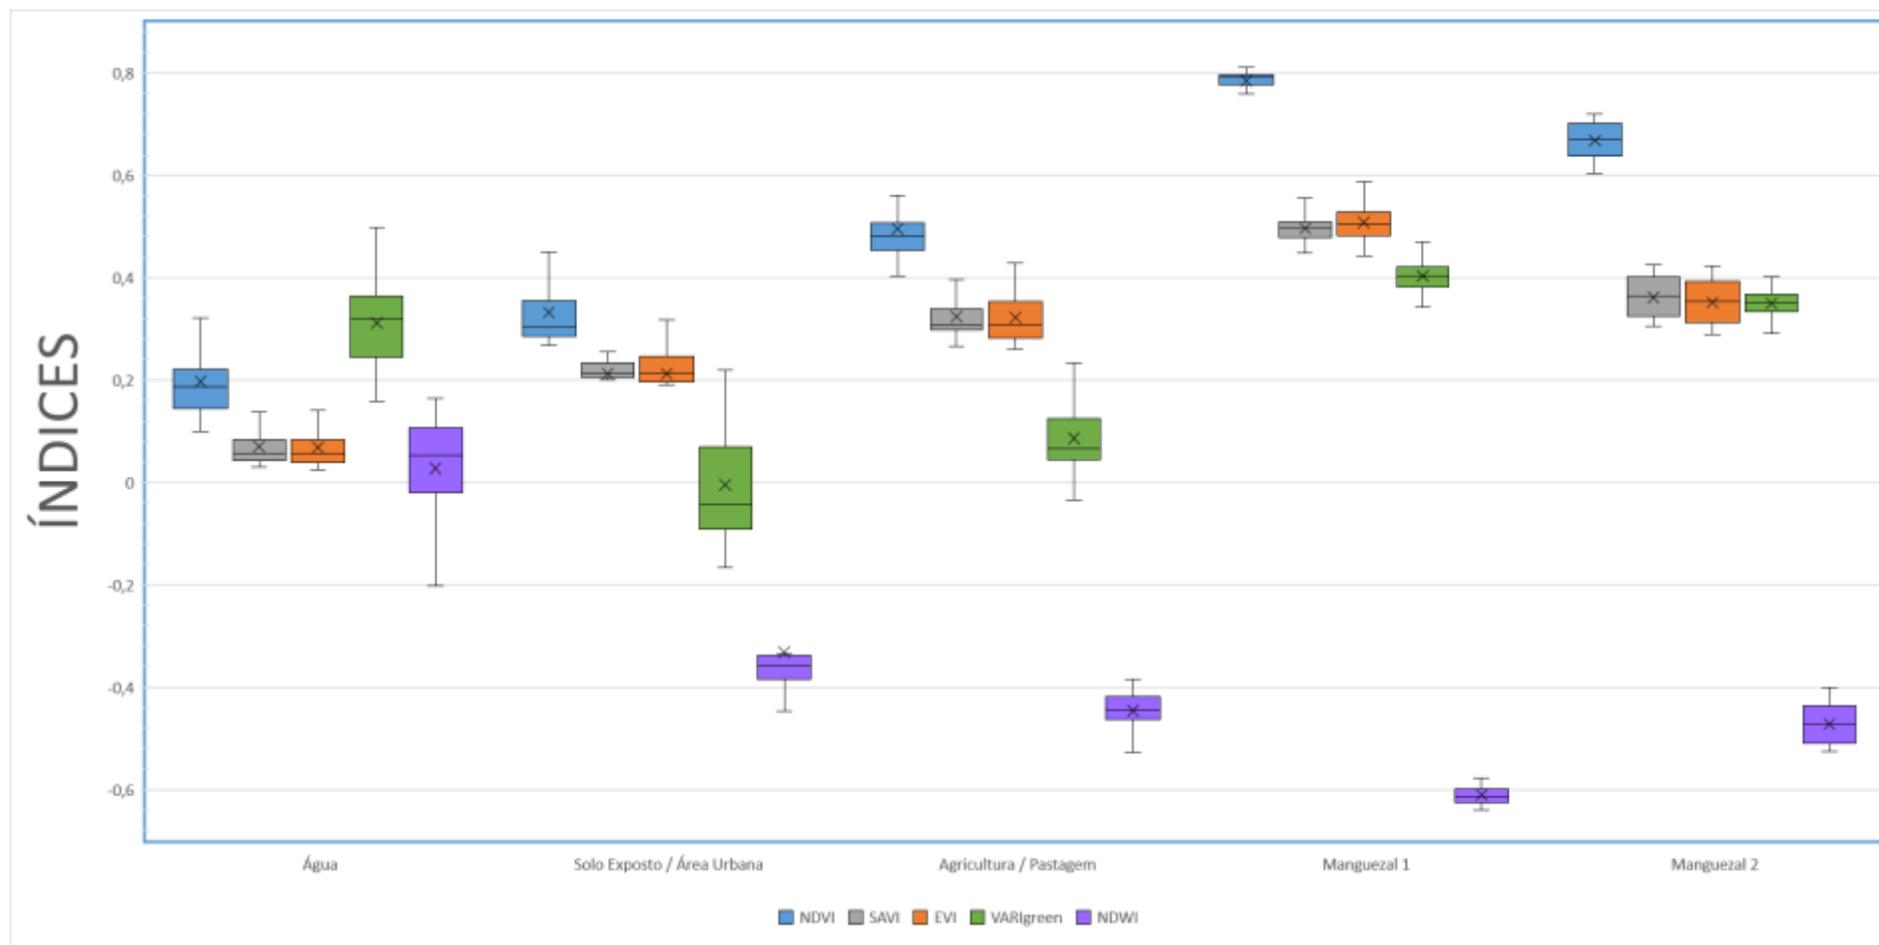
Figura 22 – Espacialização dos valores dos índices NDVI, SAVI, EVI, VARIgreen e NDWI para o ano de 2010



Fonte: o autor, 2022.

No Gráfico 8 a seguir apresentamos os *box plots* com os valores extraídos para o ano de 2010. No geral, a melhor separação entre todas as classes é obtida no índice NDVI, apenas uma pequena sobreposição dos valores de máximo e mínimo nas classes água, solo exposto/área urbana e agricultura/pastagem. Os índices SAVI, EVI e NDWI apresenta grande sobreposição de pixels entre as classes: agricultura/pastagem e manguezal 2. Esse foi o principal problema encontrado para esse ano da pesquisa. Apenas os índices NDVI e VARIgreen não apresentaram confusão entre essas duas classes. Mas ao contrário do NDVI, o índice VARIgreen não obteve um bom desempenho em nenhum outro quesito, apresentando grande sobreposição nos valores em todas as demais classes pesquisadas.

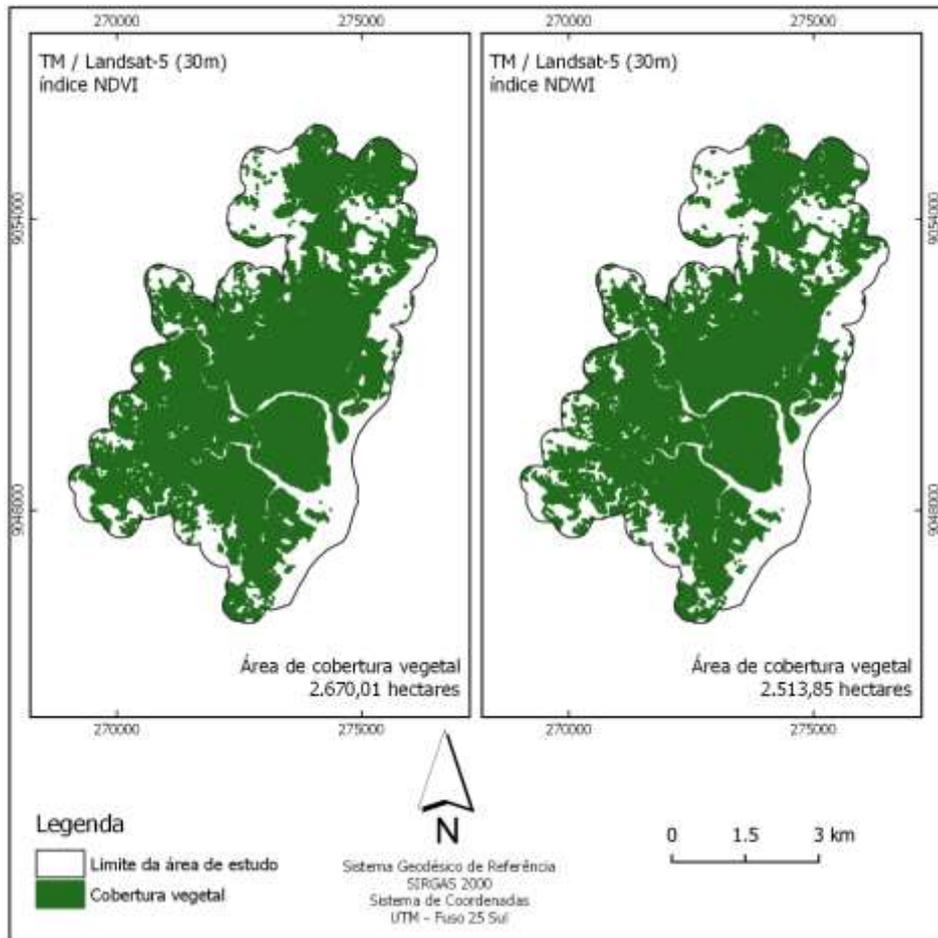
Gráfico 8 – Box plots dos índices NDVI, SAVI, EVI, VARIGreen e NDWI, ano 2010



Fonte: o autor, 2022.

Após a análise dos resultados encontrados para os índices nos anos 2000 e 2010, procedemos assim o mapeamento da cobertura vegetal nesses dois anos: para o ano 2000, o mapeamento foi realizado a partir do fatiamento das imagens índices NDVI e NDWI (Figura 23). Já para o ano de 2010, o mapeamento foi realizado a partir do índice NDVI (ver Figura 24).

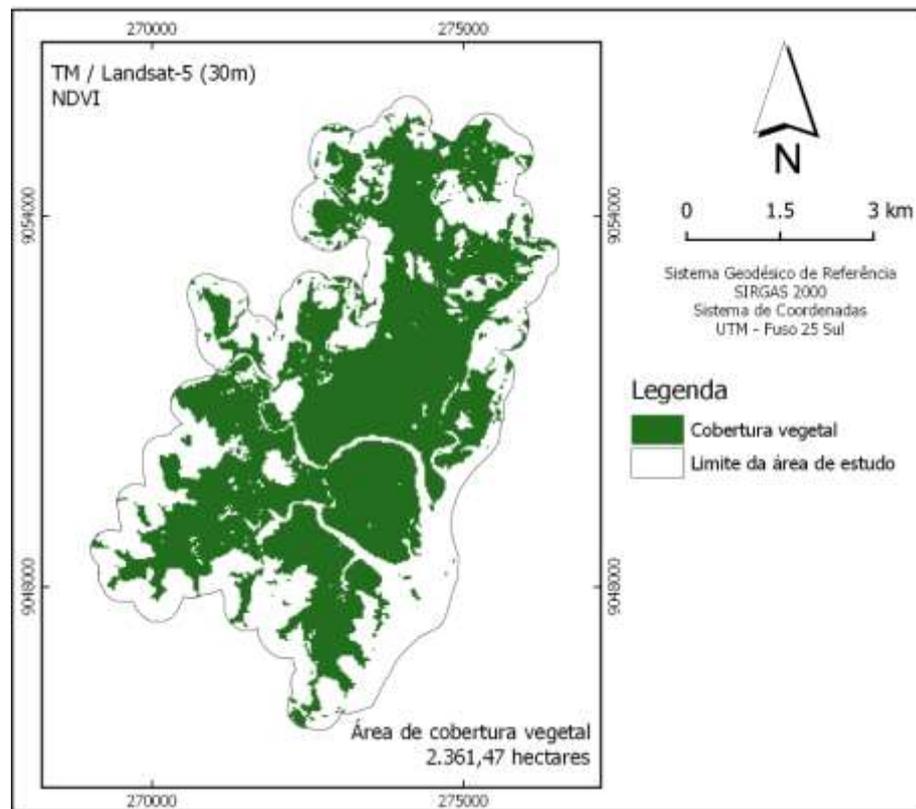
Figura 23 – Mapeamento da cobertura vegetal, ano 2000



Fonte: o autor, 2022.

O mapa de cobertura vegetal da área de estudo para o ano de 2000, apresenta um quantitativo de 2.670,01 hectares, considerando o resultado obtido a partir do índice NDVI e de 2.513,85 hectares, considerando o resultado a partir do índice NDWI. Esses valores importam uma diferença de cerca de 6,21 % entre si. Apesar da proximidade no quantitativo de áreas nos dois mapas, e utilizando como referência imagens de alta resolução do ano de 2003 obtidas na plataforma Google Earth, a imagem mais próxima disponível na plataforma, consideramos que há um exagero das áreas de vegetação nas bordas da área de estudo no mapa com dados do índice NDVI.

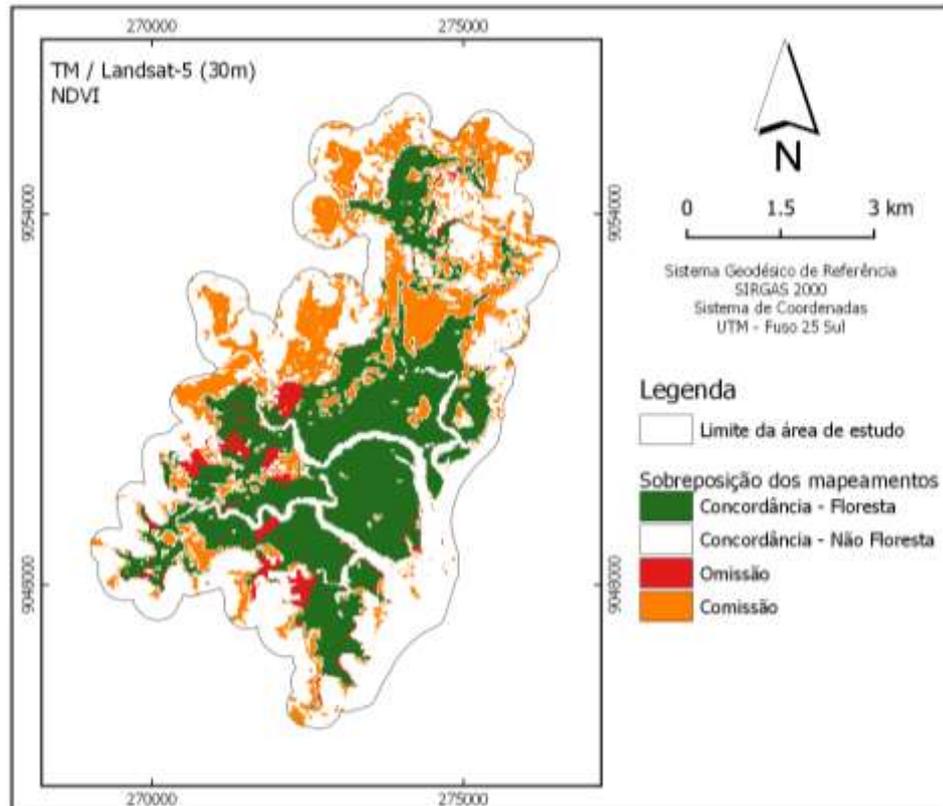
Figura 24 – Mapeamento da cobertura vegetal, ano 2010



Fonte: o autor, 2022.

O resultado obtido no ano de 2010 foi posteriormente comparado com o mapeamento realizado por Silva (2012) afim de avaliarmos ambos os produtos. E o mapa de concordância pode ser visualizado na Figura 25 abaixo:

Figura 25 – Concordância de mapeamento com o trabalho de Silva (2012)

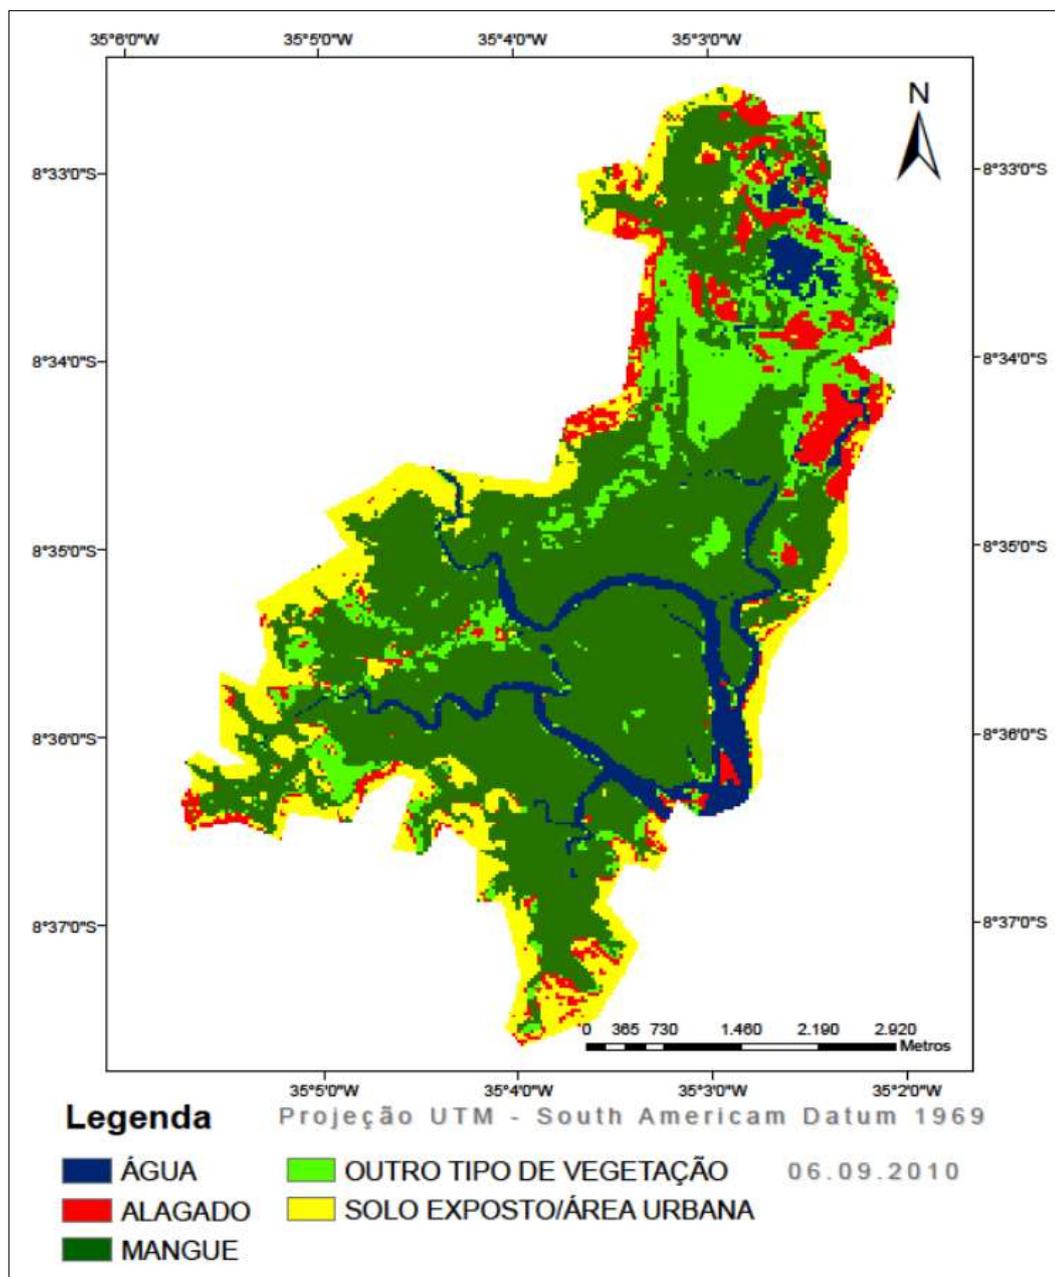


Fonte: o autor, 2022.

Os dados indicam uma concordância geral entre o mapeamento resultante desta pesquisa e o mapeamento do trabalho de Silva (2012) de 77,94%, sendo uma concordância de 45,89% das áreas sem floresta de mangue e 32,04% de concordância das áreas com mangue. O erro de Omissão foi de 3,26% e o erro de Comissão de cerca de 18,80%.

A concordância geral entre esses mapeamentos ficou abaixo da alcançada no mapeamento de 2020 e o motivo pode ser entendido a partir de análise dos dados de Erro de Comissão. A autora no seu trabalho, considera como sendo outro tipo de vegetação o que nós interpretamos aqui como sendo uma tipologia diferente de vegetação de mangue, presente principalmente na porção centro norte da região de estudo (ver Figura 26). Além disso, a área de estudo da autora é cerca de 29,13% menor que a área do nosso mapeamento o que leva a ser contabilizado como erro de comissão toda a vegetação que nós mapeamos fora dos limites do estudo da autora. Na Tabela 13 apresentamos mais detalhes acerca do mapa de concordância.

Figura 26 – Mapa de uso e ocupação da terra do estuário de Sirinhaém ano 2010



Fonte: Silva (2012).

Tabela 7 – Dados de concordância espacial da área de estudo com o mapeamento de Silva (2012)

Sensor Resolução Índice	Mangue nos dois mapeamentos (hectares)	Não Mangue nos dois mapeamentos (hectares)	% de concordância geral com o mapeamento de Silva(2012)	% de erro de comissão com o mapeamento de Silva(2012)	% de erro de omissão com o mapeamento de Silva(2012)
TM52010 30m NDVI	1282,02	1835,42	77,94	18,80	3,26

Fonte: o autor, 2022.

#### 4.5 ANÁLISE TEMPORAL DA COBERTURA VEGETAL

Por fim, sintetizando os resultados dos mapeamentos já apresentados nesse estudo, temos que, de maneira geral, a área de cobertura vegetal da área de estudo apresentou uma redução acumulada de 15,0 % entre os anos de 2000 e 2020, conforme quadro abaixo:

Ano	Índice	Área de cobertura vegetal (hectares)	Redução relativa ao mapeamento anterior ( % )
2000	NDWI	2.513,85	---
2010	NDVI	2.361,47	6,06
2020	NDVI	2.150,37	8,94
Total			15,00

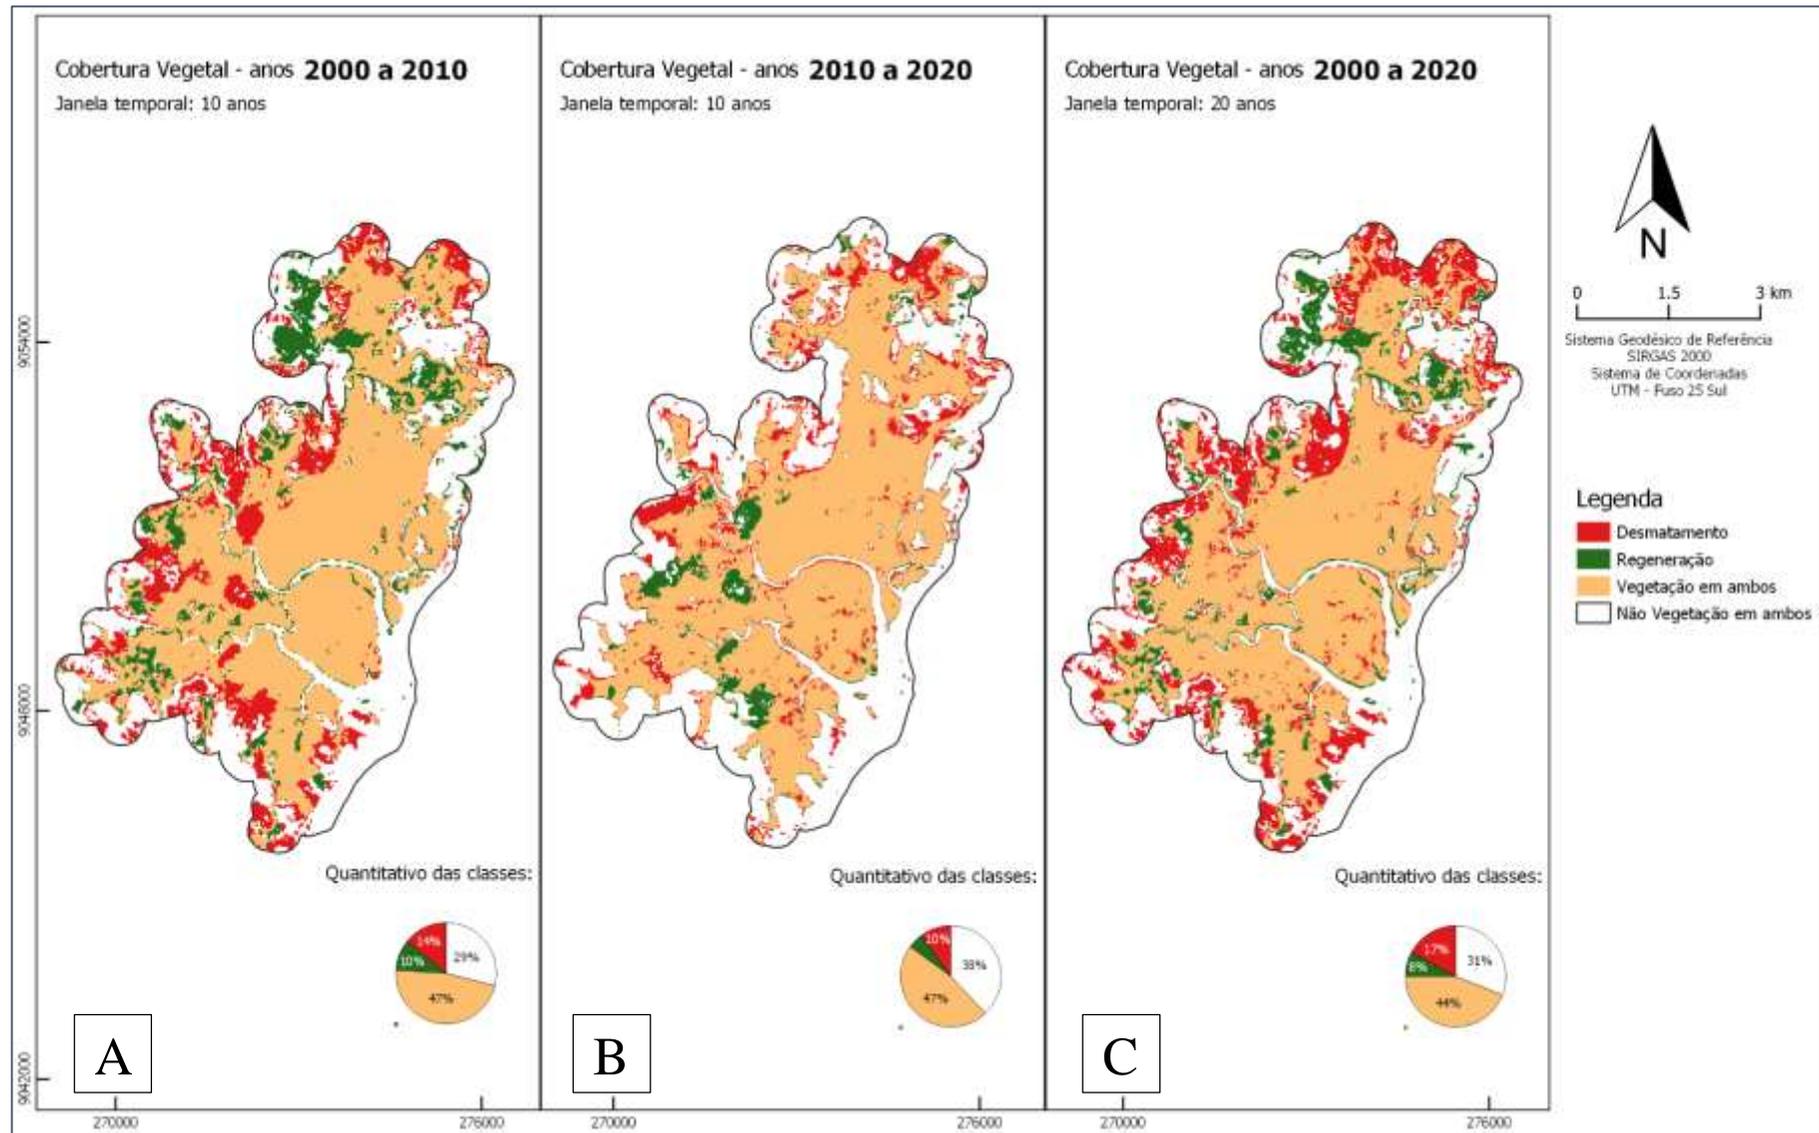
Fonte: o autor, 2022.

Na Figura 27 a seguir apresentamos afinal o mapeamento da cobertura vegetal da área de estudo ao longo dos anos da pesquisa. São apresentados no quadro A um comparativo da cobertura vegetal entre os anos de 2000 a 2010, no quadro B, dos anos 2010 a 2020 e no quadro C, um comparativo direto utilizando apenas os mapeamentos dos anos 2000 e 2020.

Observando a primeira década de mapeamento (2000 a 2010) na Figura 27-A, verificamos que dos cerca de 4.105 hectares que compõem a área de estudo, 47,5% deles (1.953 hectares) é referente a cobertura vegetal que foi mantida entre o intervalo de datas, ou seja, é a vegetação que já havia no ano 2000 e que foi conservada até o mapeamento do ano de 2010. Ainda em relação a área de estudo, cerca de 14% (560 hectares) tem relação com a vegetação que foi retirada (desmatada) no intervalo referido; e cerca de 10% (408 hectares) é referente a

cobertura vegetal que foi regenerada, ou seja, não havia no mapeamento do ano 2000 e passou a existir no mapeamento do ano de 2010. O restante da área representada pela cor branca no mapa é relativo a área que foi identificada como não vegetação nos dois mapeamentos. O mapa nos mostra que é principalmente nas bordas da área de estudo que há a maior parcela do desmatamento detectado. Essa condição é condizente com o observado nas imagens de alta resolução disponíveis pelo Google Earth e ainda com o trabalho de Silva (2012), onde percebe-se que as bordas ao norte, sul e oeste da área são amplamente aproveitadas para a cultura agrícola, principalmente da cana-de-açúcar, e também como pastagens para animais. A maior parte da área de regeneração detectada nessa primeira década refere-se a uma porção de cerca de 95 hectares presente ao noroeste da área de estudo e que, felizmente, manteve-se preservada até o ano de 2020, conforme podemos observar nos demais mapas da figura 27-B.

Figura 27 – Mapeamento multitemporal da cobertura vegetal da área de estudo



Fonte o autor, 2022.

No mapa da Figura 27-B, observamos que a condição de manutenção da situação existente é mais evidente, considerando-se tanto as áreas com cobertura vegetal como as áreas sem cobertura vegetal. Isso significa que entre os anos de 2010 e 2020 não houve mudanças tão significativas como a evidenciada na primeira década desse estudo. Ainda assim, a tendência de utilização das bordas da área foi mantida, vez que as duas maiores porções de floresta desmatada estão no limite oeste e no limite norte da área. Quantificamos então, para esse intervalo temporal, que em cerca de 47% da área de estudo (1.940 hectares) houve manutenção da vegetação já existente; em 10% (421 hectares) houve desmatamento da cobertura vegetal; em 5% (209 hectares) houve regeneração e em 38% (1535 hectares) da área não houve alteração em se tratando de áreas sem cobertura vegetal.

A Figura 27-C mostra uma análise direta do intervalo entre os anos de 2000 e 2020. A distribuição e o quantitativo das classes semelhantes ao primeiro mapa apresentado só reforça a ideia de que as maiores alterações na área de estudo ocorreram no primeiro intervalo da pesquisa, ou seja, entre os anos de 2000 e 2010. À despeito de nossa área de estudo está situada em uma Área de Proteção Ambiental – APA estuarina dos rios Sirinhaém e Maracaípe, criada ainda na década de 1980, o quadro que observamos é que desde o ano 2000 encontra-se em curso um processo gradual de ocupação e exploração das bordas da área de estudo, com efeitos práticos na redução da cobertura vegetal e consequente substituição por culturas agrícolas e pastagens.

Em relação às áreas de costa, especificamente à sudeste da área de estudo, constatamos que houve na primeira década do estudo, de 2000 e 2010, um processo de ocupação urbana no local que hoje é conhecido como Barra de Sirinhaém. A partir do ano 2010, esse processo de ocupação urbana intensificou-se, sem, contudo, implicar na abertura e desmatamento de novas áreas, mas apenas com a densificação das áreas anteriormente desmatadas.

## 5 CONCLUSÕES

As características espectrais, radiométricas, temporais e espaciais dos múltiplos sensores utilizados nesta pesquisa proporcionaram valiosas experiências na geração de índices espectrais para o estudo de vegetação de mangue sob variadas condições metodológicas. Foram analisados índices gerados a partir de imagens fusionadas e em resolução nativa, a partir de valores de reflectância e também NDs dos pixels, com dados de calibração atualizados e dados desatualizados de pré-lançamento, dentre outras situações. A experiência relatada aqui pode contribuir efetivamente com estudos de análise multisensor e índices de vegetação para a detecção, mapeamento e monitoramento da cobertura vegetal em áreas de mangue.

Os sensores MUX e WPM a bordo do novo satélite CBERS-4A, apresentaram resultados similares aos observados nos sensores OLI/Landsat-8 e MSI/Sentinel-2, já amplamente utilizados em inúmeros estudos. Dessa constatação, esperamos que haja incremento no número de estudos publicados com a utilização desses dados.

A metodologia empregada, embora não seja eficaz para a separação entre tipos diferentes de vegetação (culturas agrícolas e vegetação de mangue), gerou resultados que apresentaram bom índice de concordância com os dados de referência do projeto MapBiomas, o que a qualifica para utilização em estudos de pequenas áreas ou que demandem resultados rápidos.

O índice NDWI aplicado a cobertura vegetal de mangue resultou, na maioria dos casos, num comportamento simetricamente oposto ao índice NDVI, ou seja, alcançou os maiores valores representativos da vegetação, assim como o NDVI, mas com sinal invertido. Esse resultado, levando-se em consideração que a finalidade desse índice é para mapeamento de corpos hídricos e não cobertura vegetal, pode ser melhor analisado em trabalhos futuros, que incluam uma comparação com o índice proposto por Gao (1996).

Acerca da área de estudo, e à despeito de a mesma está situada em uma Área de Proteção Ambiental (APA estuarina dos rios Sirinhaém e Maracaípe), a situação que constatamos nesse estudo é que desde o ano 2000 encontra-se em curso um processo gradual de ocupação e exploração do entorno das florestas de mangue, com efeitos práticos na redução da cobertura vegetal e consequente substituição por culturas agrícolas e pastagens. Dessa forma, reforçamos a necessidade de melhor controle e gerenciamento da região por parte dos órgãos de preservação do meio ambiente.

O *software* QGIS, utilizado no processamento das imagens, mostrou-se robusto e confiável e com o módulo de ferramentas do GRASS GIS, foi capaz de realizar todos os procedimentos necessários ao desenvolvimento dessa pesquisa. Sua utilização para PDI pode ser recomendada por ser gratuito e livre, pela quantidade de material didático de apoio disponíveis na internet e por possuir tradução para o português.

## REFERÊNCIAS

- AKIYAMA, T. S.; MARCATO, J.; TOMMASELLI, A. M. G. Geometrical Correction of CBERS-4/PAN Images with Generalized Models Using as Reference National System of Land Management Data. **Anuário do Instituto de Geociências - UFRJ**, [S. l.], v. 41, n. 2, p. 358–368, 2018. DOI: 10.11137/2018\_2\_358\_368.
- ALMEIDA, André Quintão De; SILVA, Gilson Fernandes Da; PEZZOPANE, José Eduardo Macedo; RIBEIRO, Carlos Alexandre Damasceno. Enhanced Vegetation Index (EVI) na análise da dinâmica da vegetação da reserva biológica de Sooretama, ES. **Revista Árvore**, [S. l.], v. 32, n. 6, p. 1099–1107, 2008. DOI: 10.1590/S0100-67622008000600015.
- AMBITEC. **Laudo Biológico para Determinação da Área de Influência do Estuário do Rio Sirinhaém – PE**. Recife.
- ANJOS, Cléstiston Silva Dos. **O Sensoriamento Remoto como ferramenta para planejamento de inventários florestais por índice de vegetação**. 2017. Universidade Federal de Pernambuco, [S. l.], 2017.
- APAC. Relatório de situação de recursos hídricos do Estado de Pernambuco. **Agência Pernambucana de Águas e Clima**, [S. l.], p. 116, 2013.
- APAC. **Mapa da Bacia Hidrográfica do Rio Sirinhaém**. , 2019. Disponível em: [https://www.apac.pe.gov.br/images/GRMF/bacia\\_sirinhaém2019.jpg](https://www.apac.pe.gov.br/images/GRMF/bacia_sirinhaém2019.jpg).
- ARASATO, L. S.; BENTZ, C. M.; SILVA, R. S. B.; FONSECA, M. G.; GUERRA, J. B.; PAES, J. E. S.; FREITAS, L. R.; LUIZ, S. Uso do sensoriamento remoto óptico de alta resolução para a caracterização Manguezais, monitoramento qualitativo de manguezais. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, [S. l.], n. 1, p. 5141–5148, 2015.
- ÁVILA-FLORES, Giovanni; JUÁREZ-MANCILLA, Judith; HINOJOSA-ARANGO, Gustavo; CRUZ-CHÁVEZ, Plácido; LÓPEZ-VIVAS, Juan Manuel; ARIZPE-COVARRUBIAS, Oscar. A practical index to estimate mangrove conservation status: The forests from La Paz Bay, Mexico as a case study. **Sustainability (Switzerland)**, [S. l.], v. 12, n. 3, 2020. DOI: 10.3390/su12030858.
- BENDINI, Hugo do Nascimento; FONSECA, Leila Maria Garcia; KÖRTING, Thales Sehn; MARUJO, Rennan de Freitas Bezerra; SANCHES, Ieda Del’ Arco; ARCANJO, Jeferson de Souza. Assessment of a Multi-Sensor Approach for Noise Removal on Landsat-8 OLI Time Series Using CBERS-4 MUX Data to Improve Crop Classification Based on Phenological Features. **Revista Brasileira de Cartografia**, [S. l.], v. 69, n. 5 SE-Artigos, 2017.
- BENVINDO, Fernanda Dantas; ROCHA, Karla da Silva. AVALIAÇÃO DA TÉCNICA DE FUSÃO DE IMAGENS DO SATÉLITE LANDSAT 8 SENSOR OLI COM ORFEO MONTEVERDI. *In: Impacto, Excelência e Produtividade das Ciências Agrárias no Brasil*. [s.l.] : Atena Editora, 2020. p. 1–15. DOI: 10.22533/at.ed.7512002041.

BEZERRA, Ulisses Alencar. **Índices espectrais utilizando os sensores OLI/Landsat-8 e MSI/Sentinel-2, na bacia hidrográfica do rio Moxotó-PE**. 2019. Universidade Federal de Pernambuco, [S. l.], 2019.

CASTILLO, Jose Alan A.; APAN, Armando A.; MARASENI, Tek N.; SALMO, Severino G. Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 134, p. 70–85, 2017. DOI: 10.1016/j.isprsjprs.2017.10.016.

CHAMBERLAIN, Debbie; PHINN, Stuart; POSSINGHAM, Hugh. Remote sensing of mangroves and estuarine communities in central Queensland, Australia. **Remote Sensing**, [S. l.], v. 12, n. 1, 2020. DOI: 10.3390/RS12010197.

CONGEDO, Luca. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source Software**, [S. l.], v. 6, n. 64, p. 3172, 2021. DOI: 10.21105/joss.03172.

DINIZ, Cesar; CORTINHAS, Luiz; NERINO, Gilberto; RODRIGUES, Jhonatan; SADECK, Luís; ADAMI, Marcos; SOUZA-FILHO, Pedro. Brazilian Mangrove Status: Three Decades of Satellite Data Analysis. **Remote Sensing**, [S. l.], v. 11, n. 7, p. 808, 2019. DOI: 10.3390/rs11070808.

FAO. **The World's Mangroves 1980-2005**. FAO Forest ed. Rome, Italy: FAO, 2007. Disponível em: <http://www.fao.org/3/a1427e/a1427e00.pdf>.

FRUEHAUF, Sandra Pavan. **Rhizophora mangle (Mangue vermelho) em Áreas Contaminadas de Manguezal na Baixada Santista**. 2005. Universidade de São Paulo, [S. l.], 2005.

GAO, Bo-cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, [S. l.], v. 58, n. 3, p. 257–266, 1996. DOI: 10.1016/S0034-4257(96)00067-3.

GUARIGLIA PEREZ, Gabriel. **Uso de imagens do Sentinel-2 na estimativa de parâmetros biofísicos da vegetação em áreas de Mata Atlântica**. 2018. Universidade Federal de São Carlos, [S. l.], 2018.

HIPÓLITO, Aline Warnke. **Estudo espacial multi-resolução e espectro-temporal subpixel no mapeamento do uso e cobertura do solo**. 2017. Universidade Federal de Pelotas, [S. l.], 2017.

IBGE. **Divisão regional do Brasil em regiões geográficas imediatas e regiões geográficas intermediárias**. Rio de Janeiro. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv100600.pdf>.

IBGE. **Produto Interno Bruto dos Municípios 2019**. Rio de Janeiro. Disponível em: <https://static.poder360.com.br/2021/12/ibge-PIB-municipios-2019.pdf>.

IBGE. **IBGE Cidades**. 2021. Disponível em: <https://cidades.ibge.gov.br/>. Acesso em: 7 dez. 2021.

ICMBIO. **Atlas dos Manguezais do Brasil**. 1 ed ed. Brasília, DF. Disponível em: [http://www.icmbio.gov.br/portal/images/stories/manguezais/atlas\\_dos\\_manguezais\\_do\\_brasil.pdf](http://www.icmbio.gov.br/portal/images/stories/manguezais/atlas_dos_manguezais_do_brasil.pdf).

IVO, Carlos Tassito Corrêa; DIAS, Antônio Fernandes; MOTA, Raimundo Ivan. Estudo sobre a Biologia do Caranguejo-Uça, *Ucides cordatus cordatus* (Linnaeus, 1763), Capturado no Delta do Rio Parnaíba, Estado do Piauí. **Boletim Técnico Científico do CEPENE (Centro de Pesquisa e Extensão Pesqueira do Nordeste, Tamandaré-PE, p. 53–84, 1993.**

JENSEN, John R. **Sensoriamento remoto do ambiente: uma perspectiva dos recursos naturais terrestre**. 2. ed. São José dos Campos: Parenteses, 2009.

JUNIOR, José Marcato; COENIO, Diego Fernando; GODOI, Daniel de Faria; TOMMASELLI, Antonio Maria Garcia; RAMOS, Ana Paula Marques. Avaliação da acurácia posicional de imagens CBERS-4/PAN. In: **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**. São José dos Campos: MCTIC/INPE, 2017.

KAMAL, Muhammad; PHINN, Stuart; JOHANSEN, Kasper. Characterizing the Spatial Structure of Mangrove Features for Optimizing Image-Based Mangrove Mapping. **Remote Sensing**, [S. l.], v. 6, n. 2, p. 984–1006, 2014. DOI: 10.3390/rs6020984.

KANNIAH, Kasturi Devi; SHEIKHI, Afsaneh; CRACKNELL, Arthur P.; GOH, Hong Ching; TAN, Kian Pang; HO, Chin Siong; RASLI, Fateen Nabilla. Satellite images for monitoring mangrove cover changes in a fast growing economic region in southern Peninsular Malaysia. **Remote Sensing**, [S. l.], v. 7, n. 11, p. 14360–14385, 2015. DOI: 10.3390/rs71114360.

KUENZER, Claudia; BLUEMEL, Andrea; GEBHARDT, Steffen; QUOC, Tuan Vo; DECH, Stefan. Remote Sensing of Mangrove Ecosystems: A Review. **Remote Sensing**, [S. l.], v. 3, n. 5, p. 878–928, 2011. DOI: 10.3390/rs3050878.

LIU, Qingsheng; SONG, Hongwei; LIU, Gaohuan; HUANG, Chong; LI, He. Evaluating the Potential of Multi-Seasonal CBERS-04 Imagery for Mapping the Quasi-Circular Vegetation Patches in the Yellow River Delta Using Random Forest. **Remote Sensing**, [S. l.], v. 11, n. 10, p. 1216, 2019. DOI: 10.3390/rs11101216.

MAGRIS, Rafael Almeida; BARRETO, Raquel. Mapping and assessment of protection of mangrove habitats in Brazil. **Pan-American Journal of Aquatic Sciences**, [S. l.], v. 5, 2010.

MAIA, Luis Parente; LACERDA, Luiz Drude De; MONTEIRO, Leonardo Hislei Uchôa; SOUZA, Guilherme Marques e. **Estudo das áreas de manguezais do nordeste do Brasil: Avaliação das áreas de manguezais dos Estados do Piauí, Ceará, Rio Grande do Norte, Paraíba e Pernambuco**. Fortaleza, CE.

MARTINS, Patrick Thomaz de Aquino; BORGES, Pedro Paulino. China-Brazil Earth

Resources Satellite on global scientific literature: trends using scientometric analysis. **Boletim Goiano de Geografia**, [S. l.], v. 40, n. 01 SE-Artigos, p. 1–25, 2020. DOI: 10.5216/bgg.v40i01.62968.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, [S. l.], v. 17, n. 7, p. 1425–1432, 1996. DOI: 10.1080/01431169608948714.

MELO, Carlos Antonio Avelar De. **Modelo para estimativas de biomassa de vegetação em áreas de manguezais por técnicas de sensoriamento remoto**. 2017. Universidade Federal de Pernambuco, [S. l.], 2017.

MENESES, Paulo Roberto; ALMEIDA, Tati De. **Introdução ao processamento de imagem de sensoriamento remoto**. Brasília.

MENEZES, Marcelo. Manguezais do Nordeste. **Ciência Hoje**, [S. l.], v. 39, p. 24, 2006.

MMA, Ministério do Meio Ambiente. **Áreas Úmidas - Convenção de Ramsar**. 2022. Disponível em: <https://antigo.mma.gov.br/biodiversidade/biodiversidade-aquatica/zonas-umidas-convencao-de-ramsar.html>. Acesso em: 5 jun. 2022.

MOREIRA, Maurício Alves. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4 ed. atual ed. Viçosa-MG: Ed. UFV, 2011.

MOUSIVAND, Alijafar; MENENTI, Massimo; GORTE, Ben; VERHOEF, Wout. Multi-temporal, multi-sensor retrieval of terrestrial vegetation properties from spectral–directional radiometric data. **Remote Sensing of Environment**, [S. l.], v. 158, p. 311–330, 2015. DOI: <https://doi.org/10.1016/j.rse.2014.10.030>.

NASCIMENTO, Evely F.; AZEVEDO, Laízy De S.; CANDEIAS, Ana Lúcia B.; JÚNIOR, João R. Tavares. Comparison of water index for MUX / CBERS-4 digital number and monochrome reflectance images Comparação do índice de água para imagens MUX / CBERS-4 com número digital e reflectância monocromática. [S. l.], v. 10, p. 34–44, 2020.

NEVES, Lomanto Zogaib; MUCIDA, Danielle Piuzana. Comparação de índices de vegetação entre imagens CBERS , Landsat e Rapideye para área do Cerrado Brasileiro. **Revista Espinhaço**, [S. l.], v. 9, n. 1, p. 43–51, 2020.

PASTOR-GUZMAN, Julio; ATKINSON, Peter; DASH, Jadunandan; RIOJA-NIETO, Rodolfo. Spatiotemporal Variation in Mangrove Chlorophyll Concentration Using Landsat 8. **Remote Sensing**, [S. l.], v. 7, n. 11, p. 14530–14558, 2015. DOI: 10.3390/rs71114530.

PEREIRA, L. E.; AMORIM, G.; GRIGIO, A. M.; PARANHOS, A. C. Comparative Analysis of Normalized Difference Water Index (NDWI) Methods in Continental Wetland. **Anuário do Instituto de Geociências - UFRJ**, [S. l.], v. 41, n. 2, p. 654–662, 2018. DOI: 10.11137/2018\_2\_654\_662.

PETER, A. R.; COLLISCHONN, E.; SPIRONELLO, Rosangela Lurdes. O registro e o uso da

técnica de fusão de imagens para análise da cobertura e uso da terra na sub-bacia hidrográfica Arroio Pimenta, Arroio do Padre-RS. **Anais XVI Simposio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE, [S. l.], v. d, n. 1986, p. 6917–6922, 2013.**

PHAM, Tien; YOKOYA, Naoto; BUI, Dieu; YOSHINO, Kunihiko; FRIESS, Daniel. Remote Sensing Approaches for Monitoring Mangrove Species, Structure, and Biomass: Opportunities and Challenges. **Remote Sensing, [S. l.], v. 11, n. 3, p. 230, 2019. DOI: 10.3390/rs11030230.**

PINTO, Cibele; PONZONI, Flávio; CASTRO, Ruy; LEIGH, Larry; MISHRA, Nischal; AARON, David; HELDER, Dennis. First in-flight radiometric calibration of MUX and WFI on-board CBERS-4. **Remote Sensing, [S. l.], v. 8, n. 5, p. 1–22, 2016. DOI: 10.3390/rs8050405.**

PINTO, Cibele Teixeira. **UNCERTAINTY EVALUATION FOR IN-FLIGHT RADIOMETRIC CALIBRATION OF EARTH Doctorate Thesis Course Graduate in Remote Sensing , guided by Drs . Flávio Jorge Ponzoni , and Ruy. 2016. Instituto Nacional de Pesquisas Espaciais, [S. l.], 2016.**

PONZONI, Flávio Jorge; JUNIOR, Jurandir Zullo; LAMPARELLI, Rubens Augusto Camargo. Calibração absoluta da câmera CCD/CBERS-2. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto, [S. l.], 2005.**

PONZONI, Flávio Jorge; SHIMABUKURO, Yosio Edemir; KUPLICH, Tatiana Mora. **Sensoriamento remoto da vegetação. 2. ed. atu ed. São Paulo: Oficina de Textos, 2012.**

ROSA DOS SANTOS, Alexandre; MACHADO, Telma; SAITO, Nathália. **Spring 5.1.2 passo a passo: aplicações práticas. [s.l: s.n.].**

ROSATI, Ilaria; PROSPERI, Paolo; LATHAM, John; KAINUMA, Mami. WORLD ATLAS OF MANGROVES. *In: Terrestrial Observations of Our Planet.* Rome. p. 52.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. *In: THIRD ERTS-1 SYMPOSIUM, VOL. 1 1974, Anais [...]. : NASA SP351, 1974. p. 309–317.*

SANTOS, Luciana Cavalcanti Maia; BITENCOURT, Marisa Dantas. Remote sensing in the study of Brazilian mangroves: Review, gaps in the knowledge, new perspectives and contributions for management. **Journal of Integrated Coastal Zone Management, [S. l.], v. 16, n. 3, p. 245–261, 2016. DOI: 10.5894/rgci662.**

SANTOS, Luciana Cavalcanti Maia; MATOS, Humberto Reis; SCHAEFFER-NOVELLI, Yara; CUNHA-LIGNON, Marília; BITENCOURT, Marisa Dantas; KOEDAM, Nico; DAHDOUN-GUEBAS, Farid. Anthropogenic activities on mangrove areas (são francisco river estuary, brazil northeast): A gis-based analysis of cbers and spot images to aid in local management. **Ocean and Coastal Management, [S. l.], v. 89, p. 39–50, 2014. DOI: 10.1016/j.ocecoaman.2013.12.010.**

SHAPIRO, Aurélie; TRETTIN, Carl; KÜCHLY, Helga; ALAVINAPANAH, Sadroddin; BANDEIRA, Salomão. The Mangroves of the Zambezi Delta: Increase in Extent Observed via Satellite from 1994 to 2013. **Remote Sensing**, [S. l.], v. 7, n. 12, p. 16504–16518, 2015. DOI: 10.3390/rs71215838.

SILVA, Janaína Barbosa Da. **Sensoriamento Remoto Aplicado ao Estudo do Ecossistema Manguezal em Pernambuco**. 2012. Universidade Federal de Pernambuco - UFPE, [S. l.], 2012.

SILVA, Marcos Honorato Da. **Estrutura e Produtividade da Comunidade Fitoplanctônica de um Estuário Tropical (Sirinhaém, Pernambuco, Brasil)**. 2009. Universidade Federal de Pernambuco, [S. l.], 2009.

SILVA, Janaina Barbosa da Silva; SILVA, Danielle Gomes; MACHADO, Célia Clemente; GALVÍNCIO, Josiclêda Domiciano. Classificação geomorfológica dos estuários do estado de Pernambuco (Brasil) com base em imagens de satélite. **IV Congresso Argentino do Cuaternário y Geomorfologia, XII Congresso da Associação Brasileira de Estudos do Quaternário, II Reunión sobre el Cuaternário de América del Sur**, [S. l.], p. 117–123, 2007.

SILVA JÚNIOR, José Plácido. “Ilhados” pela cana, “suspensos” pela usina, “assituados” pela vida: des-territorialização e resistência de uma comunidade de pescadores artesanais no estuário do rio Sirinhaém, Sirinhaém - PE. [S. l.], p. 136, 2011.

SILVA, Luclécia Cristina Moraes. **Pesca artesanal no litoral sul de Pernambuco: dinâmicas identitárias e territoriais**. 2014. Universidade Federal de Pernambuco, [S. l.], 2014.

SOBRINO, José A.; JIMÉNEZ-MUÑOZ, Juan C.; PAOLINI, Leonardo. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, [S. l.], v. 90, n. 4, p. 434–440, 2004. DOI: 10.1016/j.rse.2004.02.003.

TEIXEIRA, Ariely Mayara de Albuquerque; CANDEIAS, Ana Lúcia Bezerra; TAVARES JUNIOR, João Rodrigues. Comparação dos índices de vegetação para imagens TM/Landsat 5, com correção e sem correção atmosférica. **Revista Brasileira de Geomática**, [S. l.], v. 5, n. 4, p. 524, 2017. DOI: 10.3895/rbgeo.v5n4.5428.

VALDERRAMA-LANDEROS, L.; FLORES-DE-SANTIAGO, F.; KOVACS, J. M.; FLORES-VERDUGO, F. An assessment of commonly employed satellite-based remote sensors for mapping mangrove species in Mexico using an NDVI-based classification scheme. **Environmental Monitoring and Assessment**, [S. l.], v. 190, n. 1, 2018. DOI: 10.1007/s10661-017-6399-z.

WANG, Dezhi; WAN, Bo; QIU, Penghua; SU, Yanjun; GUO, Qinghua; WANG, Run; SUN, Fei; WU, Xincai. Evaluating the Performance of Sentinel-2, Landsat 8 and Pléiades-1 in Mapping Mangrove Extent and Species. **Remote Sensing**, [S. l.], v. 10, n. 9, p. 1468, 2018. DOI: 10.3390/rs10091468.

WANG, Ting; ZHANG, Hongsheng; LIN, Hui; FANG, Chaoyang. Textural-spectral feature-based species classification of mangroves in Mai Po nature reserve from worldview-3 imagery. **Remote Sensing**, [S. l.], v. 8, n. 1, p. 1–15, 2016. DOI: 10.3390/rs8010024.

WITHARANA, Chandi; CIVCO, Daniel L.; MEYER, Thomas H. Evaluation of pansharpening algorithms in support of earth observation based rapid-mapping workflows. **Applied Geography**, [S. l.], v. 37, p. 63–87, 2013. DOI: 10.1016/j.apgeog.2012.10.008.