
COMPARAÇÃO DE IMAGENS OLI/LANDSAT-8 E MSI/SENTINEL-2 NO MAPEAMENTO DE USO E COBERTURA DA TERRA NA ILHA DO MARANHÃO

Adilson Matheus Borges **MACHADO**

Mestre em Oceanografia pelo Programa de Pós-Graduação em Oceanografia (PPGOceano) da
Universidade Federal do Maranhão

Professor Substituto da Universidade Federal do Maranhão Campus Pinheiro

E-mail: adilson.borges@ufma.br

*Recebido
Abril de 2020*

*Aceito
Maio de 2020*

*Publicado
Julho 2020*

RESUMO: Sensores de satélites ópticos com boa resolução espacial, como *Landsat Thematic Mapper (TM)* e *MSI/Sentinel-2*, são importantes fontes de informações para investigações científicas do ambiente, agricultura, silvicultura e desenvolvimento urbano. O presente estudo tem o objetivo de identificação e delimitação das diferentes classes uso e cobertura da terra da Ilha do Maranhão, buscando comparar a resposta das imagens provenientes dos sensores orbitais OLI/Landsat-8 e MSI/Sentinel-2. A metodologia partiu da obtenção de imagens orbitais da área, passando por etapas de pré-processamento, geração de NDVI, SAVI e classificação supervisionada, bem como a validação da classificação a partir do índice Kappa e Acurácia usuário e acurácia produtor, além da produção dos mapas temáticos. Os produtos NDVI Landsat-8 e Sentinel-2, apresentaram resultados similares, representando de forma satisfatória a vegetação e outros alvos (água, solo exposto e área urbana). Observa-se que após a divisão das classes (6 classes) os mesmos apresentaram diferenças visuais, principalmente na representação de solo exposto e areia úmida, causada principalmente pela mudança da condição de maré entre as imagens. A imagem OLI/Landsat-8, apresentou o índice Kappa de 0,9106 e a imagem MSI/Sentinel-2 apresentou o índice Kappa de 0,8684, que indica excelente classificação. Quando comparadas, as duas imagens OLI/Landsat-8 e MSI/Sentinel-2 mostram que são ótimas ferramentas para mapeamento de uso e cobertura da terra, ambas apresentaram resultados satisfatórios, que são confirmados pelos coeficientes Kappa, porém faz-se necessário a definição de mais classes para a imagem Sentinel que consegue detalhar melhor os alvos e diferenciar tipos e tamanhos de vegetação. Os resultados dos índices NDVI, SAVI e das classificações supervisionadas mostraram que é preciso associar estes resultados a outros índices físicos que destaquem diferentes tipos de alvo, além da implementação de novas classes, buscando uma melhor separação dos alvos terrestres.

Palavras-chave: NDVI, SAVI, Classificação Supervisionada, Sensoriamento Remoto.

COMPARISON OF OLI/ LANDSAT-8 AND MSI/SENTINEL-2B IMAGES IN COVER AND LAND USE MAPPING IN THE IN THE NORTH SECTOR OF MARANHÃO ISLAND

ABSTRACT: Optical satellite sensors with good spatial resolution, such as Landsat Thematic Mapper (TM) and MSI / Sentinel-2, are important sources of information for scientific investigations of the environment, agriculture, forestry and urban development. This study aims to identify and delimit the different land use and land cover classes of Maranhão Island, seeking to compare the response of images from the OLI / Landsat-8 and MSI / Sentinel-2 orbital sensors. The methodology started from obtaining orbital images of the area, going through stages of pre-processing, generation of NDVI, SAVI and supervised classification, as well as the validation of the classification using the Kappa and User Accuracy and Producer Accuracy, in addition to the production of thematic maps. The NDVI Landsat-8 and Sentinel-2 products showed similar results, satisfactorily representing vegetation and other targets (water, exposed soil and urban area). It is observed that after dividing the classes (6 classes) they showed a visual difference, mainly in the representation of exposed soil and wet sand, caused mainly by the change in the tidal condition between the images. The OLI / Landsat-8 image presented the Kappa index of 0.9106 and the MSI / Sentinel-2 image presented the Kappa index of 0.8684, which indicates an excellent classification. When compared, the two OLI / Landsat-8 and MSI / Sentinel-2 images show that they are excellent tools for mapping land use and coverage, both presented satisfactory results, which are confirmed by the Kappa coefficients, but it is necessary to define more classes for the Sentinel image that can better detail the targets and differentiate types and sizes of vegetation. The results of the NDVI, SAVI and supervised classifications showed that it is necessary to associate these results with other physical indices that highlight different types of targets, in addition to the implementation of new classes, seeking a better separation from ground targets.

Keywords: NDVI, SAVI, Supervised Classification, Remote Sensing.

COMPARACIÓN DE IMÁGENES OLI / LANDSAT-8 Y MSI / SENTINEL-2B EN LA CUBIERTA Y EL MAPA DE USO DE LA TIERRA EN LA ISLA MARANHÃO

RESUMEN: Los sensores ópticos satelitales con buena resolución espacial, como Landsat Thematic Mapper (TM) y MSI / Sentinel-2, son fuentes importantes de información para investigaciones científicas del medio ambiente, la agricultura, la silvicultura y el desarrollo urbano. Este estudio tiene como objetivo identificar y delimitar las diferentes clases de uso y cobertura de la tierra de la isla de Maranhão, buscando comparar la respuesta de las imágenes de los sensores orbitales OLI / Landsat-8 y MSI / Sentinel-2. La metodología comenzó con la obtención de imágenes orbitales del área, pasando por etapas de preprocesamiento, generación de NDVI, SAVI y clasificación supervisada, así como la validación de la clasificación utilizando Kappa y la precisión del usuario y la precisión del productor, además de la producción de mapas temáticos. Los productos NDVI Landsat-8 y Sentinel-2 mostraron resultados similares, representando satisfactoriamente la vegetación y otros objetivos (agua, suelo expuesto y área urbana). Se observa que después de dividir las clases (6 clases) mostraron una diferencia visual, principalmente en la representación del suelo expuesto y la arena húmeda, causada principalmente por el cambio en el estado de las mareas entre las imágenes. La imagen OLI / Landsat-8 presentó el índice Kappa de 0.9106 y la imagen MSI / Sentinel-2 presentó el índice Kappa de 0.8684, lo que indica una clasificación excelente. Cuando se compararon, las dos imágenes OLI / Landsat-8 y MSI / Sentinel-2 muestran que son excelentes herramientas para mapear el uso y la cobertura de la tierra, ambas presentaron

resultados satisfactorios, que son confirmados por los coeficientes de Kappa, pero es necesario definir Más clases para la imagen Sentinel que pueden detallar mejor los objetivos y diferenciar los tipos y tamaños de vegetación. Los resultados de las clasificaciones NDVI, SAVI y supervisadas mostraron que es necesario asociar estos resultados con otros índices físicos que resaltan diferentes tipos de objetivos, además de la implementación de nuevas clases, buscando una mejor separación de los objetivos terrestres.

Palavras claves: NDVI, SAVI, Clasificación supervisada, Detección Remota.

INTRODUÇÃO

O monitoramento ambiental utilizando dados de satélites de micro e mesoescala, considerando a resolução espacial dos sensores, avançou após o lançamento pelos Estados Unidos em 1972, do primeiro satélite Terra (do inglês, *Earth*) do sensor *Thematic Mapper* dos satélites da série Landsat (MOREIRA, 2007). Na década de 60 o Sensoriamento Remoto (SR) começava a ser utilizado para análise e interpretação de fotografias aéreas e imagens orbitais com o objetivo de identificar e classificar diferentes materiais na superfície terrestre. Na era moderna o SR na perspectiva da paisagem e seus produtos, é uma ferramenta bastante utilizada para monitoramento da cobertura vegetal e suas mudanças (RIBEIRO et al., 2016). A obtenção de informações de imagens com o objetivo de realizar monitoramentos ambientais pode ser realizada com o auxílio de métodos de classificação automática de imagens e/ou interpretação visual (VASCONCELOS e NOVO, 2004).

A classificação é o processo de extração de informação em imagens para reconhecer padrões e objetos homogêneos e são utilizados em Sensoriamento Remoto para mapear áreas da superfície terrestre que correspondem aos temas de interesse. Os procedimentos de classificação são executados no ambiente do Sistema de Informação Geográfica (SIG) e consistem na identificação automática realizada pelo software, o resultado da classificação digital é apresentado por meio de classes espectrais (áreas que possuem características espectrais semelhantes), uma vez que um alvo dificilmente é caracterizado por uma única assinatura espectral (NOVO, 2010; ABREU e COUTINHO, 2014). A interpretação visual de imagens de satélites é um método muito eficaz para o mapeamento do uso e cobertura da terra (BEZERRA et al., 2019; OLIVEIRA e AQUINO, 2019; FREIRES et al., 2020). Sensores de satélites ópticos com boa resolução espacial, como *Landsat Operational Land Imager* (OLI) e MSI/Sentinel-2, são importantes fontes de informações para investigações científicas das atividades de agricultura e silvicultura e desenvolvimento urbano (RICHTER, 1996).

Alguns índices de vegetação estão sendo bastante utilizados para classificação do uso e cobertura da terra (MAGALHÃES et al., 2017). No presente estudo foi utilizado o Índice de

Vegetação da Diferença Normalizada (IVDN, do inglês *Normalized Difference Vegetation Index* - NDVI) descrito por Rouse et al. (1973) e o Índice de Vegetação Ajustado ao Solo (IVAS, do inglês *Soil Adjusted Vegetation Index* - SAVI) descrito por Huete (1988). A estimativa desses índices foi possível utilizando as bandas espectrais de imagens OLI/Landsat-8 e MSI/Sentinel-2.

Ponzoni e Shimabukuro (2009) afirmam que a cobertura vegetal serve como um importante indicador da qualidade biofísica de um ambiente e podem ser estimadas por meio de métodos de índices de Vegetação. Bhandari et al. (2012) afirmam que cada objeto na superfície terrestre possui um comportamento espectral diferente, com suas características próprias. Os cientistas ainda possuem esforços conjuntos para desenvolver sensores e algoritmos mais modernos que permitam o processamento visual e digital de imagens para extrair informações biofísicas da superfície da terra, buscando caracterizar de maneira mais precisa os usos e coberturas da terra a partir de dados de Sensoriamento Remoto (JENSEN, 2011).

Serra e Filho (2019) com base na interpretação e análise das formas de uso e ocupação do solo por meio da classificação de imagens de satélite Landsat-5, sensor TM, observaram modificações nos padrões de uso e cobertura da terra promovidas pela ação humana nos últimos 30 anos (1984-2010) na Zona Costeira Norte de São Luís (MA) no município de São Luís, revelando que o processo de urbanização está expresso principalmente no adensamento da malha urbana da cidade e, conseqüentemente, redução da cobertura de vegetação, em consequência do crescimento populacional. A Ilha do Maranhão encontra-se em um processo intenso de urbanização e ocupação do espaço, e esse processo causa conseqüências, como as alterações nos sistemas ambientais (COSTA et al., 2016).

Assim, a partir da problemática exposta e em busca de melhores técnicas para identificação e delimitação das diferentes classes de uso e cobertura da terra na Ilha do Maranhão, o presente estudo busca comparar a resposta das imagens provenientes dos sensores orbitais OLI/Landsat-8 e MSI/Sentinel-2, a fim de definir qual dos produtos pode ser melhor empregado com eficácia na gestão e planejamento de recursos naturais e expansão urbana sustentável, compreensão dos processos vegetacionais e diagnóstico da dinâmica no espaço urbano e rural.

METODOLOGIA DA PESQUISA

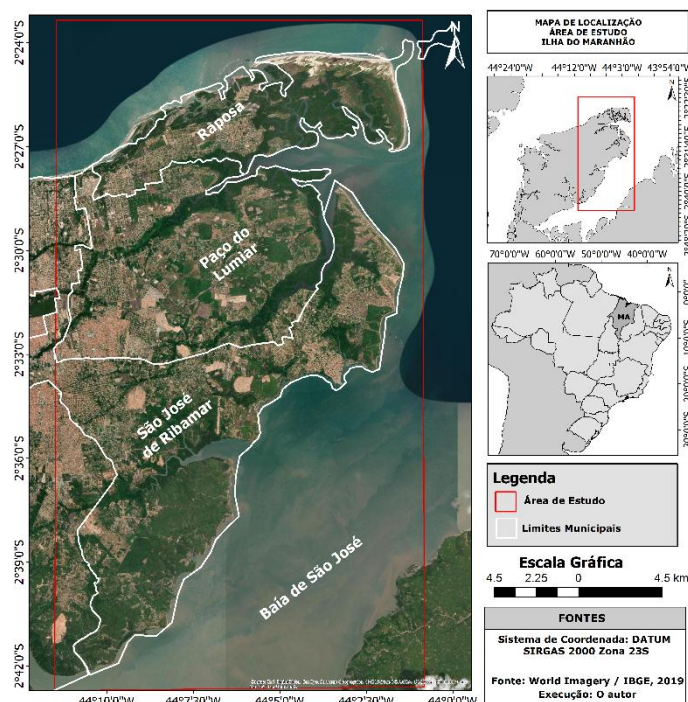
Área de Estudo

A área de estudo compreende grande parte da Ilha do Maranhão (Figura 1) e compreende os Municípios de Paço do Lumiar, Raposa e uma parte de São José de Ribamar, a Ilha está localizada na região costeira do Estado do Maranhão, limitando-se ao Norte com o Oceano Atlântico; ao Sul, com a Baía de São José e o Estreito dos Mosquitos; a Leste, com a de São José; e a Oeste, com a Baía de São Marcos (MARANHÃO, 2011).

A Ilha do Maranhão apresenta uma estrutura geológica predominantemente sedimentar, relacionada às transgressões e regressões marinhas, possui feições geomorfológicas caracterizadas por formações de praias arenosas e lodosas, dunas móveis, paleodunas, manguezais, marismas e uma extensa rede de canais, que são preenchidos a cada ciclo de preamar. Ao centro, sul e oeste, os manguezais, recortados por canais de maré, se relacionam à geomorfologia do Litoral Ocidental e do interior do Golfão Maranhense (MARANHÃO, 2002; FEITOSA e TROVÃO, 2006; EL-ROBRINI *et al.*, 2006; RODRIGUES, 2018). A região de estudo é caracterizada por uma variedade de ecossistemas estuarinos e marinhos diversos e pouco explorados, esta é influenciada por marés semidiurnas (ocorrência de duas baixa-mares e duas preamares por dia), com macromarés que podem chegar a 7 m de altura nas grandes sizíguas, com média de 6,6 m nas preamares, as correntes de maré podem chegar a $2,5 \text{ m s}^{-1}$ e alturas das ondas em torno de 0,6 a 1,4 m (EL-ROBRINI *et al.*, 2006). (SOUSA *et al.* 2008; RIBEIRO, *et al.* 2018).

Segundo a classificação climática de Köppen, o clima da área de estudo corresponde ao tipo Aw (quente e úmido), apresentando dois períodos distintos: um chuvoso que se estende de janeiro a junho, apresentando alto índice pluviométrico e outro seco de julho a dezembro com precipitações anuais de cerca de 1750 mm (abaixo da normal climatológica 1760 mm), temperaturas do ar máximas anuais atingem $35 \text{ }^{\circ}\text{C}$ e mínimas de $24 \text{ }^{\circ}\text{C}$, umidade relativa do ar anual média de 78% e evapotranspiração anual de 2200 mm (INMET, 2020).

Figura 1 - Mapas de localização da área de interesse (destacado em vermelho), a área de estudo na Ilha do Maranhão abrangendo os municípios de Paço do Lumiar, São José de Ribamar e Raposa



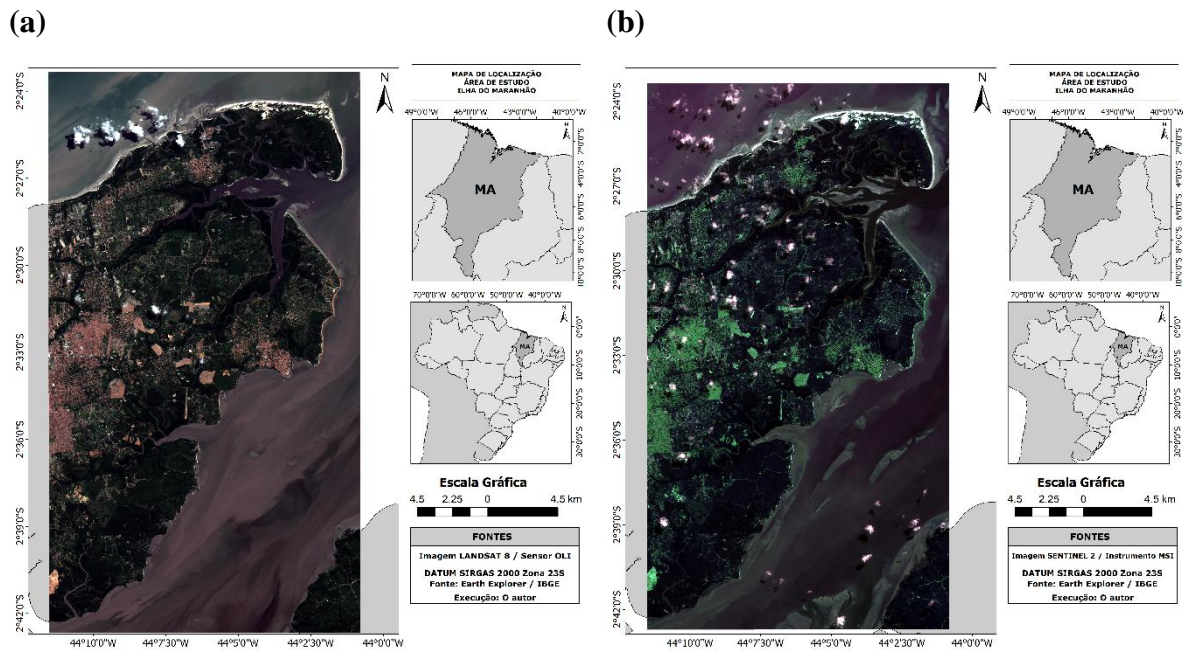
Fonte: o autor

Materiais

Buscando atingir o objetivo do presente estudo foram obtidas imagens orbitais do sensor *Multispectral Instrument* (MSI), instalado a bordo do satélite Sentinel-2B. Também foram adquiridas imagens do sensor OLI do satélite Landsat-8, as quais são comumente utilizadas para este tipo de estudo (Tabela 1). O satélite MSI/Sentinel-2 possui 13 faixas espectrais, semelhantes com as do OLI/Landsat-8, no entanto algumas bandas apresentam resoluções de 10 m (ESA, 2018). As imagens foram adquiridas por meio do Serviço Geológico dos Estados Unidos (USGS) no endereço: <http://earthexplorer.usgs.gov> (USGS, 2018).

As análises foram realizadas com as cenas mais recentes e sem a presença de nuvens com intuito de avaliar melhor os resultados. Para isso buscou-se imagens em período de seca na região, que ocorre entre julho e dezembro. A imagem do sensor Landsat-8/OLI foi gerada no dia 05/09/2019, enquanto que a cena do Sentinel-2/MSI em 29/06/2019 (Figura 2).

Figura 2 - Cenas utilizadas no estudo. (a) Landsat-8/OLI gerada no dia 05/09/2019 e (b) Sentinel-2/MSI gerada no dia 29/06/2019



Fonte: O autor

Para a avaliação foram escolhidas imagens de datas próximas para evitar a interferência de mudanças de uso e cobertura da terra. A tabela 1 apresenta as descrições dos sensores OLI/Landsat-8 e MSI/Sentinel-2 com as respectivas bandas do espectro óptico utilizadas no presente estudo, é possível perceber que a diferença entre o tamanho do pixel dos produtos analisados é um fator a ser considerado. O *software* livre QGIS 3.10.4 foi utilizado para pré-processamento das imagens, processamento do NDVI, segmentação e classificação supervisionada e produção dos mapas.

Tabela 1 - Descrições das bandas multiespectrais do sensor OLI/Landsat-8 e do MSI/Sentinel-2.

<i>Bandas Sentinel-2/MSI</i>	Comprimento de onda central (nm)	<i>Bandas Sentinel-2/MSI</i>	Comprimento de onda central (nm)
Banda 1 - Aerosol	443	Banda 1 - Aerosol	443
Banda 2 - Azul	483	Banda 2 - Azul	490
Banda 3 - Visível Verde	561	Banda 3 - Visível Verde	560
Banda 4 - Visível Vermelho	654	Banda 4 - Visível Vermelho	665
Banda 5 - Infravermelho Próximo	864	Banda 5 - Vermelho	705
Banda 6 - Infravermelho Médio	1609	Banda 6 - Vermelho	740
Banda 7 - Infravermelho Médio	2201	Banda 7 - Vermelho	783
		Banda 8 - Infravermelho Próximo	842
		Banda 8a - Vermelho	865
		Banda 9 - Vapor de Água	945
		Banda 10 - Cirrus	1375
		Banda 11 - Infravermelho Médio	1610
		Banda 12* Infravermelho Médio	2190
Órbita	220	Órbita	38

Ponto	62	Ponto	-----
Resolução Espacial	30 m	Resolução Espacial	10, 20 e 60 m
Largura da Faixa Imageada	185 km	Largura da Faixa Imageada	290 km
Revisita	16 dias	Revisita	10 dias
Quantificação	16 bits	Quantificação	12 bits
Data da Imagem	05/09/2019	Data da Imagem	29/06/2019
Identificação	LC08_L1TP_220062_2019 0504_20190520_01_T1	Identificação	L1C_T23MNT_A0120 76_20190629T132241

Fontes: USGS (Science for a Changing World). [https://earth.esa.int/web/sentinel/user-guides/sentinel-2-
msi/resolutions/radiometric](https://earth.esa.int/web/sentinel/user-guides/sentinel-2-
msi/resolutions/radiometric).

Métodos

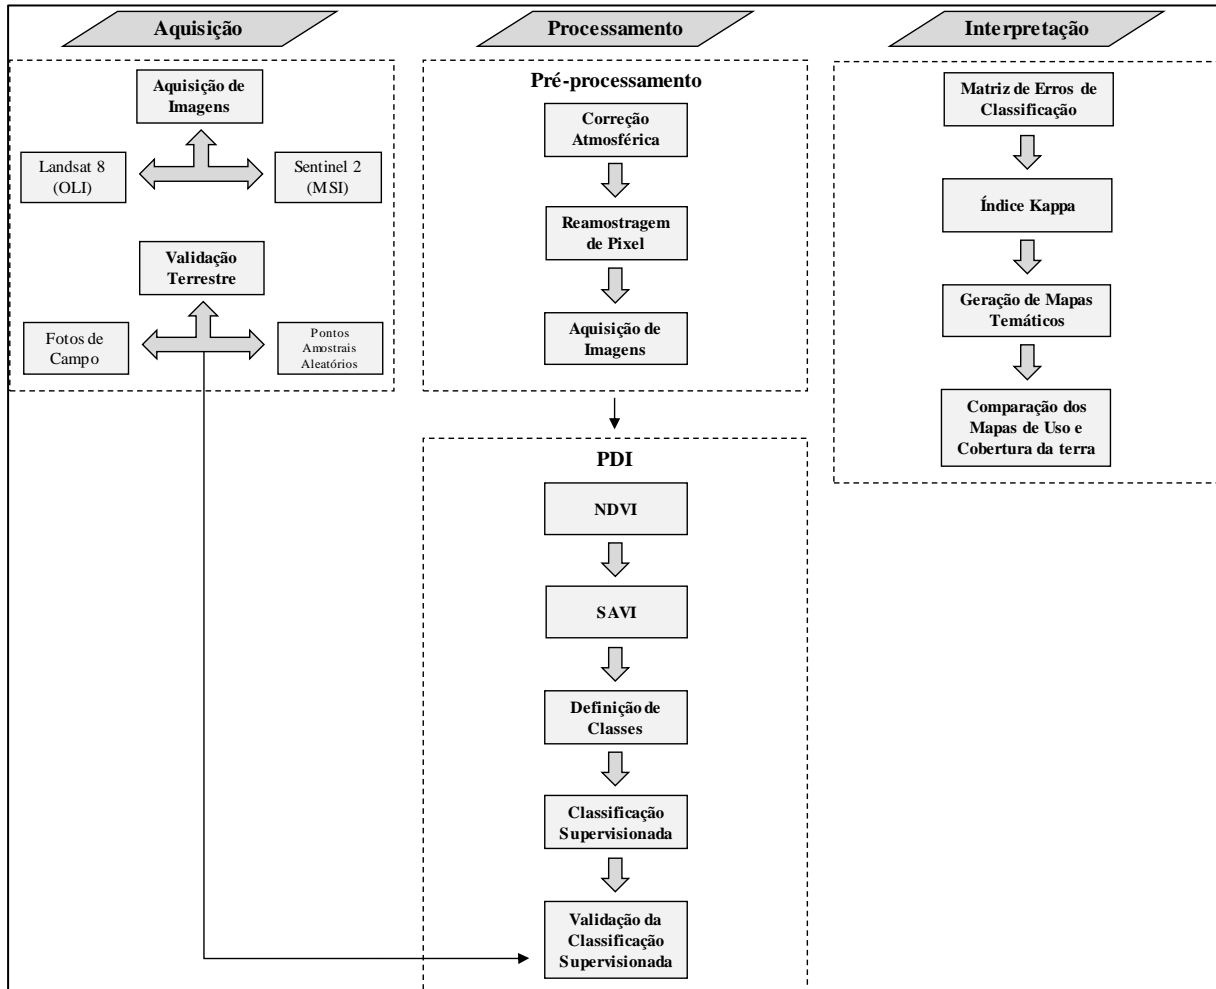
Pré-Processamento

A atmosfera reduz o contraste de objetos em uma imagem de satélite. A correção atmosférica é o procedimento que tira o efeito de dispersão molecular e absorção por gases, como vapor de água, ozônio, oxigênio e aerossóis, este procedimento consiste em duas etapas principais: estimativa de parâmetros e recuperação da refletância da superfície (RICHTER, 1996; LIANG *et al.*, 2001). Este processo de correção também é muito importante para o cálculo de índices de vegetação computados a partir de duas ou mais bandas espectrais em virtude da influência do espalhamento atmosférico (MATHER, 1999; FREIRES *et al.*, 2020). A correção atmosférica das imagens OLI/Landsat-8 e MSI/Sentinel-2 foi realizada utilizando o processo de Subtração do Pixel Escuro (DOS, do inglês *Dark Object Subtraction*) (CHAVEZ JUNIOR, 1988; CHAVEZ JUNIOR, 1996), com o uso do programa QGIS 3.10.4 com auxílio da ferramenta *Preprocessing* do *plugin Semi-Automatic Classification*.

Com as imagens em refletância de superfície, foi feito o empilhamento das bandas multiespectrais de cada sensor com o auxílio da ferramenta *Band set* do *plugin Semi-Automatic Classification* do *software* QGIS 3.10.4. No sensor OLI/Landsat-8 com 30m de resolução multiespectral e 15 m na banda pancromática, sendo todas as imagens georreferenciadas na projeção cartográfica Universal Transversa de Mercator; DATUM - SIRGAS 2000; zona 23 hemisfério sul, uma fusão das imagens foi realizada para combinar a informações espectrais das bandas multiespectrais com a informação geométrica (espacial) mais detalhada da banda pancromática com o objetivo de melhorar a resolução das imagens (WALD *et al.* 1997; NOVACK, 2009; RODRIGUES, 2014) com o auxílio da ferramenta *Band set* do *plugin Semi-Automatic Classification* do *software* QGIS 3.10.4. Nas imagens do MSI/Sentinel-2 foi feito um empilhamento das bandas de melhor resolução espacial (10 m, ou seja, as bandas 2, 3, 4 e 8), com o auxílio da ferramenta *Band set* do *plugin Semi-Automatic*

Classification do software QGIS 3.10.4. Os processamentos das imagens OLI/Landsat-8 e MSI/Sentinel-2 estão sintetizados na Figura 3.

Figura 3 – Fluxograma Metodológico das atividades desenvolvidas neste trabalho.



Fonte: organização do autor

Processamento Digital de Imagens (PDI)

Índice de Vegetação por Diferença Normalizada (IVDN)

O Índice de Vegetação da Diferença Normalizada (IVDN, do inglês *Normalized Difference Vegetation Index* - NDVI) descrito por Rouse et al. (1973) é um índice utilizado em pesquisas de análises ambientais, pois permite fazer análises sobre a cobertura vegetal de determinada região em diversas escalas. O NDVI é um índice muito utilizado aliado as imagens de satélites, pois, reduz o efeito topográfico e apresenta uma escala de medida linear entre -1 e 1, os valores próximos de +1 indicarão a presença de vegetação, ou seja, quanto maior o valor do índice, maior será a presença de vegetação. Enquanto os valores próximos a

-1 representarão os alvos urbanos, solo exposto e água (PRATES, 2020). No presente estudo, este índice foi calculado com o auxílio da ferramenta *Raster Calculator* do *software* QGIS 3.10.4.

Allen et al. (2002) e Rouse (1973) destacaram o uso de imagens NDVI no realce da vegetação em relação aos instrumentos urbanos, água e ao solo exposto, sendo obtido pela razão entre a diferença da refletância do infravermelho próximo (NIR) e a refletância do vermelho (R), dividida, respectivamente, pela soma das mesmas, como mostra a equação 1:

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad (\text{Eq. 1})$$

Índice de Vegetação Ajustado ao Solo (IVAS)

O Índice de Vegetação Ajustado ao Solo (IVAS, do inglês *Soil Adjusted Vegetation Index* - SAVI) descrito por Huete (1988) foi desenvolvido através das limitações observadas no Índice de Vegetação da Diferença Normalizada (NDVI). Jensen (2009) destaca o desenvolvimento um índice que pudesse melhorar os valores de NDVI sem necessidades de validações ou mensurações em campo. O índice foi melhorado a partir de uma constante determinada “L”, a constante L foi introduzida para minimizar o brilho do solo. A constante L pode apresentar valores variáveis de 0 a 1, variando segundo a própria cobertura vegetal, dependendo do ajuste com o substrato do dossel. De acordo com Huete (1988) apud Ponzoni, Shimabukuro (2009); Prates (2020), os valores ótimos de L são:

L = 1 (para baixas densidades de vegetação);

L = 0,5 (para médias densidades de vegetação);

L = 0,25 (para altas densidades de vegetação).

Com o OLI/Landsat 8, as bandas utilizadas são a 4 e a 5, devido a inserção de banda do azul, resultado da maior sensibilidade do sensor à menores comprimentos de onda. Para o cálculo do SAVI, as características da área pesquisada sugeriram um valor de L no estágio da antese de 0,20 (MARINO e ALVINO, 2020). O SAVI é obtido pela multiplicação de 1 + L pela razão entre a diferença da refletância do infravermelho próximo (NIR) pela refletância do vermelho (R), dividida respectivamente pela soma das mesmas adicionado ao L, este foi calculado com o auxílio da ferramenta *Raster Calculator* do *software* QGIS 3.10.4. Para este índice, Huete (1988) propôs a equação 2:

$$SAVI = \frac{(1 + L)x(NIR - R)}{(NIR + R + L)} \quad (\text{Eq. 2})$$

Classificação Supervisionada

Através das informações das classes espectrais das áreas que possuem características semelhantes, uma vez que um alvo dificilmente é caracterizado por uma única assinatura espectral, um mapa de "pixels" classificados, representados por símbolos gráficos ou cores é construído, ou seja, o processo de classificação digital transforma um grande número de níveis de cinza em cada banda espectral em um pequeno número de classes em uma única imagem (NOVO, 2010; ABREU e COUTINHO, 2014). A definição das classes de cobertura da terra foi realizada a partir da interpretação visual da imagem, do conhecimento obtido da região, da análise do Plano Diretor das cidades e com base nos critérios de Florenzano (2002) e Jensen (2009). Após estes procedimentos, foram definidas 6 classes de cobertura da terra (água, área urbana, solo exposto, areia úmida, mangue e vegetação arbustiva) encontradas na área de estudo, a classificação supervisionada foi obtida com o auxílio do *plugin Semi-Automatic Classification Plugin (SCP)* do *software QGIS 3.10.4*, o método utilizado foi o *Maximum Likelihood*.

Validação da Classificação Supervisionada

Para validar os resultados e aprimorar a análise foram utilizadas informações auxiliares com o auxílio do *software Google Earth Pro*, com o objetivo de coletar amostras de campo para uma inspeção visual das classificações geradas em planilha eletrônica, utilizando-se os dados gerados pelo *plugin SCP* do *software QGIS 3.10.4*. Em seguida, as classificações foram avaliadas por uma matriz de confusão e índice Kappa (\widehat{K} – Equação 3), para verificação da veracidade do resultado da classificação de uma imagem (MOREIRA, 2005).

$$\widehat{K} = \frac{P_0 - P_e}{1 - P_e} \quad (\text{Eq. 3})$$

Onde: \widehat{K} = índice de exatidão Kappa; P_0 = Concordância total ou Exatidão global; P_e = concordância esperada. Conforme o índice Kappa, a classificação do mapa temático foi avaliada através de seus índices qualitativos conforme descrito por Landis e Koch (1977) (Tabela 2).

Tabela 2 - Classes e desempenho do Índice Kappa. Adaptado de Landis & Koch (1977).

Classes do índice	Desempenho
< 0	Péssimo
0 – 0,2	Ruim
0,21 – 0,4	Razoável
0,41 – 0,6	Bom
0,61 – 0,8	Muito Bom
0,81 – 1,0	Excelente

Fonte: Adaptada de Landis e Koch (1977).

A acurácia é uma medida de precisão que indica a probabilidade de um pixel de referência ser classificado corretamente por meio da análise de erros de omissão e comissão presentes na classificação. A chamada “acurácia do usuário” ou confiabilidade, é indicativa da probabilidade de um pixel classificado no mapa (ou imagem) realmente representar essa categoria no terreno, é a razão entre o número de elementos adequadamente classificados numa dada classe e o total de elementos da mesma classe (Equação 4) (STORY e CONGALTON, 1986; CONGALTON, 1991; CONGALTON & GREEN 1999).

$$au = \frac{x_{ii}}{x_{i+}} \quad (\text{Eq. 4})$$

Onde: au = acurácia do usuário; X_{ii} = Número de elementos classificados corretamente; X_{i+} = Total de elementos classificados para uma classe i .

A medida de precisão chamada de "acurácia do produtor" indica que o número total de pixels corretos em uma categoria dividido pelo número total de pixels dessa categoria, conforme derivado dos dados de referência (Equação 5). Essa medida de precisão indica a probabilidade de um pixel de referência ser classificado corretamente e é realmente uma medida de erro de omissão (STORY e CONGALTON, 1986; CONGALTON, 1991; CONGALTON & GREEN 1999).

$$ap = \frac{x_{ii}}{x_{+i}} \quad (\text{Eq. 4})$$

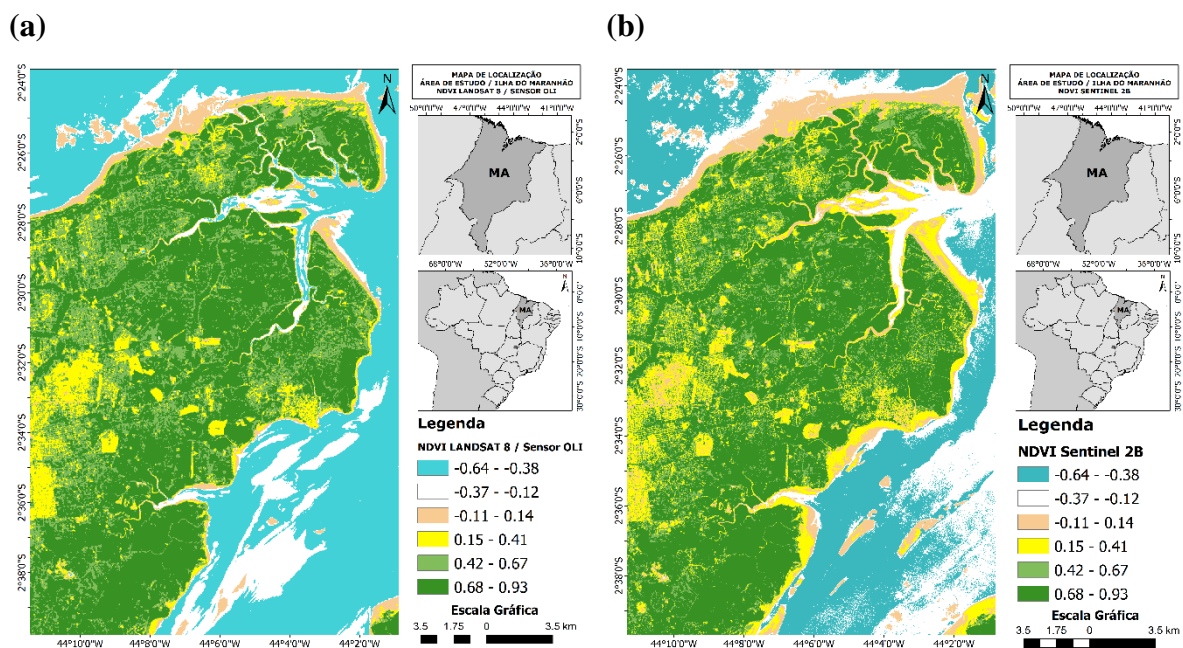
Onde: ap = acurácia do produtor; X_{ii} = Número de elementos classificados corretamente; X_{+i} = Total de elementos classificados para uma classe i .

RESULTADOS E DISCUSSÃO

Mapeamento dos índices de vegetação NDVI

Os resultados mapeados dos Índices de Vegetação da Diferença Normalizada (IVDN, do inglês *Normalized Difference Vegetation Index* - NDVI) das imagens OLI/Landsat-8 e MSI/Sentinel-2 da Ilha do Maranhão são apresentados nas Figuras 4a e 4b, $NDVI_{OLI}$ e $NDVI_{MSI}$, respectivamente.

Figura 4 - Mapas dos Índices de Vegetação NDVI referente a imagem. (a) OLI/Landsat-8 e (b) MSI/Sentinel-2.



Os resultados apresentados são similares, representando de forma satisfatória a vegetação e outros alvos (água, solo exposto e área edificada), variando de -0,64 a 0,93. Apesar dos índices apresentarem diferenças entre os valores mínimos e máximos, observa-se que após a divisão das classes (6 em ambos) os mesmos apresentaram diferença visual entre a carta do $NDVI_{MSI}$ e $NDVI_{OLI}$, principalmente na representação de solo exposto e areia úmida, esta interferência é causada principalmente pela mudança da condição de maré entre a imagem do OLI/Landsat-8 (maré alta) e o MSI/Sentinel-2 (maré baixa), mostrando influência das macromarés da região.

Conforme Ponzoni et al. (2012), valores negativos de NDVI correspondem a água; valores muito próximos de 0 correspondem a superfície não vegetada; e quanto mais próximo de 1, mais densa é a vegetação. Na representação da superfície não vegetada, que pode

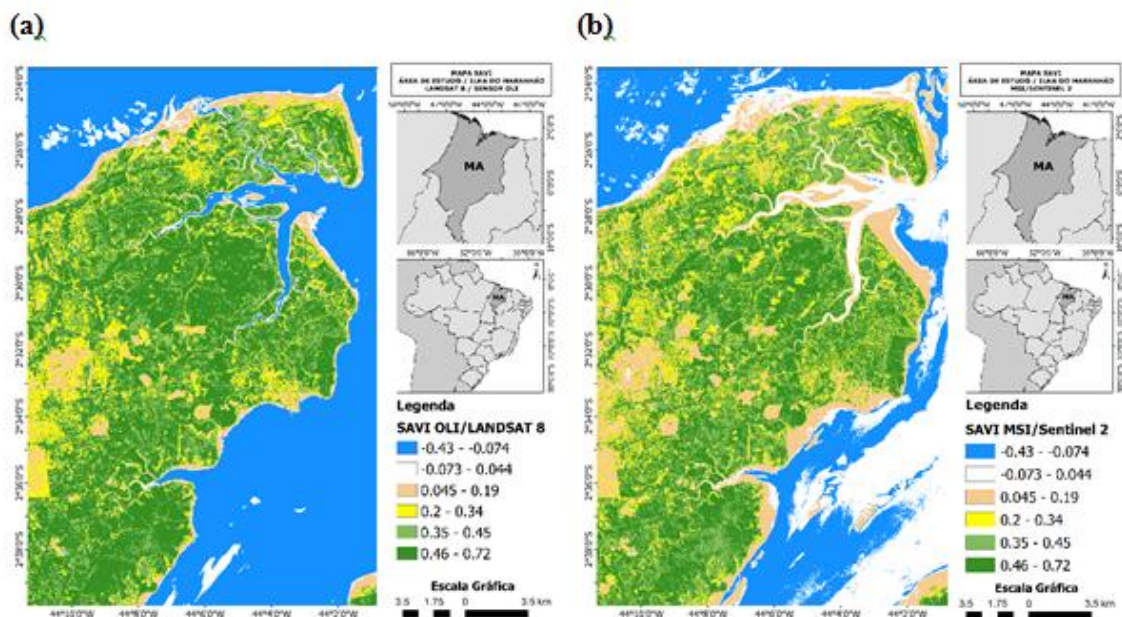
corresponder a aglomeração urbana, a carta do $NDVI_{MSI}$ representou com mais detalhes a superfície não vegetada e $NDVI_{OLI}$ com menor riqueza de detalhes. Cunha et al. (2012) observou a influência do aumento da elevação, como fator influente para o desenvolvimento da vegetação. Silva e Galvêncio (2012) afirmam durante o período seco os valores NDVI são subestimados e durante período chuvoso os altos índices indicam um aumento de biomassa.

Gandhi et al. (2015) afirmam que os valores de NDVI variaram de um máximo de 0,5 a um mínimo de 0,1, no qual constataram que os valores mais baixos são encontrados nos solos menos vegetados, justificado pela maior reflexão no solo que possui baixos valores na faixa do infravermelho próximo e altos na faixa do vermelho. Jensen (2011) afirma que valores positivos crescentes indicam aumento de vegetação verde, enquanto valores negativos indicam superfícies sem vegetação como água, solo exposto e neve ou nuvens. Classes como rochas, solos expostos e pastagens degradadas têm refletâncias similares e o resultado no índice de vegetação é aproximadamente zero.

Mapeamento dos índices de vegetação SAVI

Os resultados mapeados dos Índices de Vegetação Ajustado ao Solo (IVAS, do inglês *Soil Adjusted Vegetation Index - SAVI*) das imagens OLI/Landsat-8 e MSI/Sentinel-2 da Ilha do Maranhão são apresentados nas Figuras 5a e 5b, Landsat-8 ($SAVI_{OLI}$) e Sentinel-2 ($SAVI_{MSI}$), respectivamente.

Figura 5 - Mapas dos Índices de Vegetação SAVI referente a imagem. (a) OLI/Landsat-8 e (b) MSI/Sentinel-2.



Fonte: O autor

De acordo com as classes de SAVI a classe de valores inferiores a 0,25 corresponde principalmente a territórios artificializados. A classe de valores acima de 0,45 corresponde principalmente a florestas folhosas e mistas, como florestas de mangues. Os solos heterogêneos são bastante destacados nos índices SAVI, solos secos, úmidos, com densidade ou baixa cobertura vegetal através deste método e são facilmente identificados. Os valores de 0,21 a 0,40 e 0,41 a 0,60 também podem ser classificados como índices que identificam solo exposto e uma baixa densidade de área foliar.

Os valores de IVAS tendem a diminuir em áreas artificializadas e com vegetação mais aberta, sofrendo mais efeitos do solo exposto (GIONGO et al., 2007; MACHADO et al., 2009). Ribeiro et al. (2016) analisando os índices SAVI e adotando $L=1$, encontraram valores para o período úmido variando de um valor máximo de 0,80 a um valor mínimo de -0,29. Ribeiro et al. (2016) faz uma síntese dos trabalhos de Silva (2012) e Ferreira et al. (2013), eles afirmam que entre os índices estudados (Refletância, Índice de Umidade - NDWI, NDVI e Albedo de Superfície) a Refletância da vegetação de mangue e o Índice de Umidade apresenta correlação com vegetação de mangue. O albedo apresentou uma correlação inversa e o índice NDVI, não tendo destacado a vegetação de mangue. Eles afirmam também que no manual não se recomenda usar o SAVI em manguezais, pois este tipo de ecossistema agrupa vários tipos de vegetação.

Classificação Supervisionada

As Tabelas 3 e 4 apresentam as matrizes de erros das classificações supervisionadas geradas a partir das imagens OLI/Landsat-8 e MSI/Sentinel-2, respectivamente. A matriz de erros de classificação mostra a distribuição de porcentagem de *pixels* classificados correta e erroneamente. E por meio dos resultados destas matrizes, o coeficiente Kappa é calculado, que indicam a qualidade do mapeamento realizado. Como pode ser observado na tabela 3, na classificação supervisionada da imagem OLI/Landsat-8, o índice Kappa apresentou o valor de 0,9106, que indica uma excelente classificação conforme a tabela 2 de desempenho Kappa.

Verifica-se o baixo percentual de acurácia do usuário para as classes areia úmida e mangue, que indica um baixo percentual de acerto de classificação em relação a verdade terrestre e também um baixo percentual de acerto de pixel de referência classificado corretamente para essas classes, também foi possível encontrar uma baixa acurácia produtor na classe de mangue, que indica a probabilidade de um pixel de referência ser classificado corretamente.

Este processo pode estar relacionado com a resolução espacial do OLI/Landsat-8 que dificulta o operador durante a classificação dos diferentes extratos vegetacionais de mangues e da diferenciação entre solo exposto (areia seca) e areia úmida que fica exposta durante cada maré baixa da região. Estes processos são somados com o avanço das áreas urbanas, que realizam o corte, tornando as áreas com diferentes fisionomias, que contribuem para dificultar a interpretação dos alvos.

Tabela 3 - Matriz de erros de classificação em % da imagem OLI/Landsat-8.

Classes	Água	Área Urbana	Areia Úmida	Mangue	Solo Exposto	Vegetação Arbustiva	Total	Acurácia Usuário	Kappa
Água	97,42	0,00	0,34	40,36	0,17	0,00	69,49	98,90	0
Área Urbana	0,00	98,10	6,20	0,00	0,02	1,77	5,15	92,93	0
Areia Úmida	0,60	0,66	65,29	1,93	0,38	0,10	1,99	73,23	0
Mangue	1,88	0,00	22,76	57,60	0,66	2,09	3,21	32,97	0
Solo Exposto	0,10	0,01	0,03	0,12	97,39	1,28	7,85	97,03	0
Vegetação Arbustiva	0,00	1,23	5,38	0,00	1,38	94,77	12,31	97,66	0
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	0	0
Acurácia Produtor	97,42	98,10	65,29	57,60	97,39	94,77	0	95,67	0
Kappa	0	0	0	0	0	0	0	0	0,9106

Fonte: Organização do autor

A Tabela 4, apresenta a matriz de erros da classificação supervisionada da imagem MSI/Sentinel-2, o índice Kappa apresentou o valor de 0,8684, que indica uma excelente classificação conforme a tabela 2 de desempenho Kappa.

Verifica-se o baixo percentual de acurácia do usuário para a classe de mangue e solo exposto e uma baixa acurácia produtor na classe de vegetação arbustiva. A alta resolução do MSI/Sentinel-2 acaba demonstrando uma necessidade de um maior número de classes a serem identificadas durante a classificação, como por exemplo a adição da classe vegetação rasteira, na figura 6b é possível perceber a melhor resolução e distinção entre as classes, porém em algumas áreas, nota-se uma baixa distinção entre o mangue e a vegetação arbustiva, que diminuiu o valor de acurácia produtor.

Tabela 4 - Matriz de erros de classificação em % da imagem do MSI/Sentinel-2.

Classes	Água	Área Urbana	Areia Úmida	Mangue	Solo Exposto	Vegetação Arbustiva	Total	Acurácia Usuário	Kappa
Água	98,27	0,57	11,07	0,09	0,20	0,06	59,60	98,17	0
Área Urbana	0,01	89,58	0,15	0,53	1,68	2,06	9,96	96,92	0
Areia Úmida	0,32	0,41	87,29	0,13	7,40	0,12	8,37	95,46	0
Mangue	0,00	0,20	0,04	95,06	0,00	36,77	11,85	67,11	0
Solo Exposto	1,40	1,35	1,41	0,01	90,54	0,12	2,61	57,08	0
Vegetação Arbustiva	0,00	7,88	0,04	4,17	0,17	60,83	7,61	84,16	0
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	0	0
Acurácia Produtor	98,27	89,58	87,29	95,06	90,54	60,83	0	91,99	0
Kappa	0	0	0	0	0	0	0	0	0,8684

Fonte: Organização do autor

Ao observar as classes de uso e cobertura da terra definidas para o presente estudo, é possível identificar uma certa compatibilidade na distribuição espacial das classes temáticas. Contudo, como pode ser verificado na Tabela 5 e no gráfico da Figura 6, que traz um comparativo das áreas das classes mapeadas de ambas as imagens, as unidades de Cobertura e uso da terra apresentaram algumas variações na extensão de suas áreas. Essas diferenças na extensão das áreas estão relacionadas às diferentes resoluções espaciais das imagens utilizadas, como descrito na metodologia.

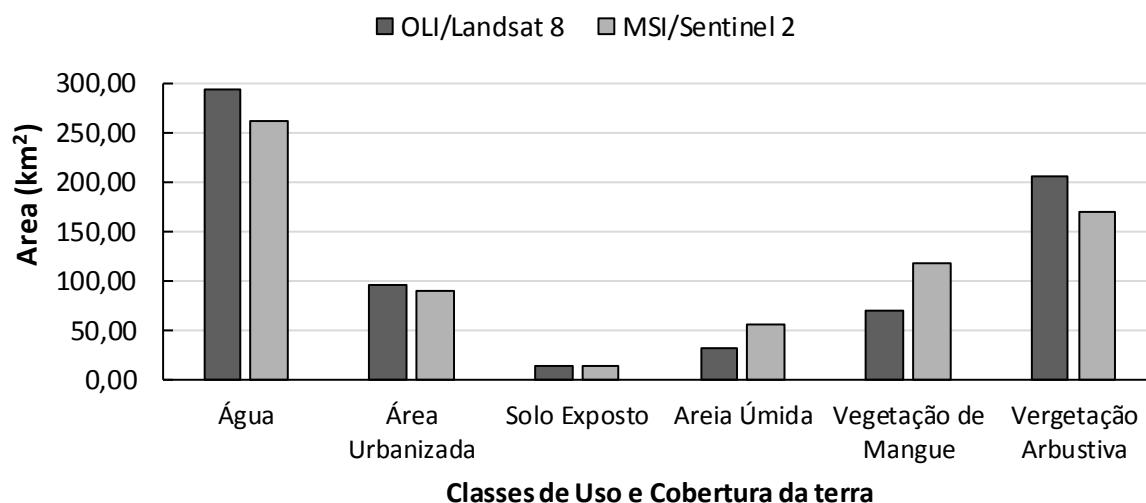
Assim, sensores que apresentem uma relativa diferença entre suas resoluções espaciais, como na comparação entre OLI/Landsat-8 e MSI/Sentinel-2, apresentam diferenças visíveis entre as classes de uso e cobertura da terra, justamente pela melhor capacidade de definição dos alvos do sensor MSI, sendo capaz de diferenciar duas ou mais classes numa mesma área, onde no sensor OLI seria normalmente uma classe.

Tabela 5 - Comparação entre as áreas das classes de uso e cobertura da terra obtidas a partir da classificação supervisionada das imagens OLI/Landsat-8 e MSI/Sentinel-2.

Classes	OLI/Landsat-8	MSI/Sentinel-2
Água (km ²)	293,13	261,47
Área Urbana	95,45	89,03
Areia Úmida (km ²)	14,56	13,84
Mangue (km ²)	31,44	56,23
Solo Exposto (km ²)	68,85	117,78
Vegetação Arbustiva (km ²)	205,08	169,93

Fonte: Organização do autor

Figura 6 - Comparação entre as áreas das classes de uso e cobertura da terra obtidas a partir da classificação supervisionada das imagens OLI/Landsat-8 e MSI/Sentinel-2.



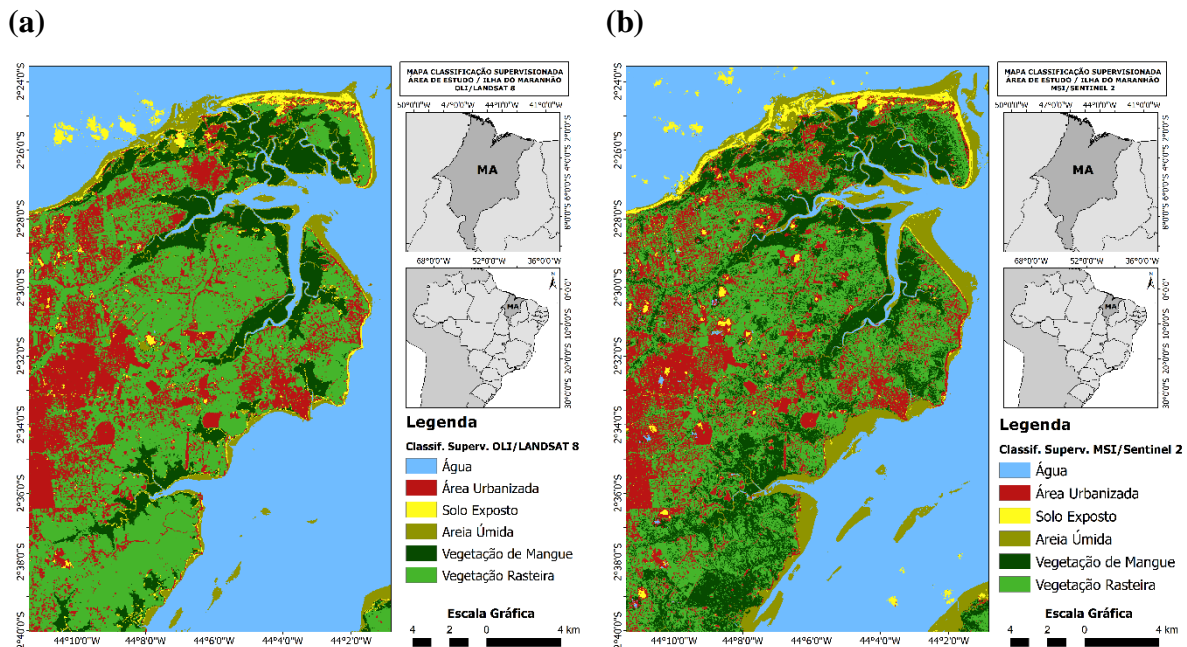
Fonte: Organização do autor

As Figuras 7a e 7b apresentam os mapas gerados a partir da classificação supervisionada obtidas das imagens OLI/Landsat-8 e MSI/Sentinel-2, respectivamente. As variações de áreas das classes uso e cobertura da terra podem ser visualizadas nos mapas temáticos.

No mapa gerado a partir da imagem MSI/Sentinel-2 constatou-se que as classes Solo Exposto e Mangue, na cor amarela e verde escuro respectivamente, estão mais disseminadas quando comparadas a imagem do OLI/Landsat-8, sendo possível identificar com maior clareza a diferenciação entre duas ou mais classes numa mesma área, a classe de Mangue se individualiza e “incorpora” as áreas de Vegetação Arbustiva. Assim como é possível perceber

uma maior ocorrência da classe Areia Úmida, na cor marrom, que devido a melhor resolução e a condição de maré baixa imageada no MSI/Sentinel-2, que fica claro pela diferença quando comparado a imagem do OLI/Landsat-8, que está em uma condição de maré alta.

Figura 7 - Mapas de Classificação Supervisionada referente a imagem: (a) OLI/Landsat-8 e (b) MSI/Sentinel-2.



Torna-se necessário destacar que a partir da definição de classes temáticas para os índices de vegetação, obteve-se no mesmo intervalo de classes alvos com comportamento espectral semelhante devido à dificuldade de separação das assinaturas espectrais. Silva (2003) afirma que a alta resolução dos sensores está diretamente relacionada com a maior discriminação dos elementos, logo a um número maior de observações, no entanto o inverso também é válido, a baixa resolução está relacionada a uma pobre distinção dos objetos imageados. Freires et al. (2020) mostram que a diferença de resolução espacial das imagens contribui para respostas espectrais distintas.

Quando comparadas, as duas imagens OLI/Landsat-8 e MSI/Sentinel-2 mostram que são ótimas ferramentas para mapeamento de uso e cobertura da terra, ambas apresentaram resultados satisfatórios, que são confirmados pelos coeficientes Kappa apresentados nas tabelas 3 e 4. A resolução radiométrica inferior do sensor MSI do satélite MSI/Sentinel-2 (12 bits) em relação ao OLI/Landsat-8 (16 bits) não comprometeu os resultados.

CONCLUSÃO

Assim, a partir da problemática exposta e em busca de melhores técnicas para identificação e delimitação das diferentes classes uso e cobertura da terra da Ilha do Maranhão utilizando imagens provenientes dos sensores orbitais OLI/Landsat-8 e MSI/Sentinel-2, este trabalho verificou, a partir do Índice de Vegetação por Diferença Normalizada, Índice de Vegetação Ajustado ao Solo e Classificação Supervisionada que as cenas apresentaram boa representação.

A classificação resultante da imagem do satélite MSI/Sentinel-2 teve as classes de mangue superestimadas na classe ocupada por vegetação arbustiva, fazendo-se necessário a definição de mais classes para a região. A Areia Úmida da imagem MSI/Sentinel-2 apresentou maior área também, isto ocorreu em decorrência a condição de maré baixa. O OLI/Landsat-8 demonstrou alvos mais homogêneos, tendo o número de classes subestimados. A classificação da imagem OLI/Landsat-8 apresentou índice Kappa de 0,9106 indicando um excelente desempenho. Enquanto a classificação da imagem MSI/Sentinel-2 apresentou índice Kappa de 0,8684, que atesta também uma excelente classificação. De modo geral, faz-se necessário acrescentar mais classes no mapeamento deste setor da Ilha do Maranhão.

A análise do mapeamento dos índices NDVI mostrou que há diferenças espectrais e espaciais dos produtos gerados entre os sensores ópticos OLI/Landsat-8 e MSI/Sentinel-2 e que o satélite Sentinel-2 permitiu, um maior delineamento dos alvos. A análise do mapeamento dos índices SAVI também mostrou esse comportamento, o satélite Sentinel-2 consegue detalhar melhor os alvos, como solo exposto, areia úmida e área urbana. A diferença entre a condição de maré entre as duas imagens, causa diferenças entre as classes de areia úmida e solo exposto durante os movimentos de maré baixa e maré alta. Assim, o índice NDVI pode ser considerado também uma importante ferramenta em conjunto com outras técnicas em Sensoriamento Remoto, para o planejamento de uso individual.

Estudos com multisensores destacam características individuais de cada sensor. Os resultados dos índices NDVI, SAVI e das classificações supervisionadas mostraram que é preciso buscar associação a outros índices físicos que destaquem diferentes tipos de alvo, como por exemplo o Índice Normalizado de Diferença de áreas construídas - NDBI (melhor contraste em áreas construídas) e Índice de Umidade - NDWI (destaque para conteúdo hídrico), além da implementação de novas classes, buscando uma melhor separação dos alvos terrestres.

BIBLIOGRAFIA

ABREU, K. M. P.; COUTINHO, L. M. Sensoriamento remoto aplicado ao estudo da vegetação com ênfase em índice de vegetação e métricas da paisagem. **Vértices. Campos dos Goytacazes, Rio de Janeiro**, v. 16, n. 1, p. 173-198, 2014.

ALLEN, R. G.; TASUMI, M.; TREZZA, R.; WATERS, R.; BASTIAANSEN, W. **Surface Energy Balance Algorithms for Land (SEBAL)**. Advanced Training and users Manual, Kimberly, Idaho, v.1,0, 97p. 2002.

BEZERRA, U. A.; de OLIVEIRA, L. M. M.; CANDEIAS, A. L. B.; da SILVA, B. B.; LEITE, A. C. L. D. S.; SILVA, L. T. M. D. S. Comparativo do Índice de Vegetação de Diferença Normalizada (NDVI) entre os Sensores OLI-Satélite Landsat-8 e MSI-Satélite Sentinel-2 em Região Semiárida. **Anuário do Instituto de Geociências**, v. 41, n. 3, p. 167-177, 2019.

BHANDARI, A. K.; KUMAR, A.; SINGH, G. K. Feature Extraction using Normalized Difference Vegetation Index (IVDN): A Case Study of Jabalpur City. **Procedia Technology**, v. 6, 2012.

CHAVEZ JUNIOR, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, p. 459-479, 1988.

CHAVEZ JUNIOR, P. S. Image-based atmospheric corrections – revisited and improved. **Photogrammetric Engineering and Remote Sensing**, v. 62, p. 1025-1036, 1996.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, 37(1), 35-46. 1991.

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: principles and practices**. New York, Lewis Publishers. 137 p. 1999.

COSTA, I. R. S.; TEIXEIRA, E. C.; COSTA, C. M.; BARROS, D. V.; SILVA, Q. D. Alagamentos e enxurradas: uma análise do uso e cobertura do solo na sub-bacia hidrográfica do riacho do Turu São Luís-MA. **Revista Geonorte**, v. 7, p. 1-13, 2016.

CUNHA, J. E.; RUFINO, I. A.; SILVA, B. B. D.; CHAVES, I. D. B. Dinâmica da cobertura vegetal para a Bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 5, p. 539-548, 2012.

EL-ROBRINI, M.; ALVES, M. A. M. S.; MARQUES JR., V.; EL-ROBRINI, M. H. S.; FEITOSA, A. C.; TAROUÇO, J. E. F.; SANTOS, J. H. S.; VIANA, J. R. Maranhão. In: Dieter Muehe. (Org.). **Erosão e Progradação no Litoral Brasileiro**. Brasília: Ministério do Meio Ambiente, 2006, V. P. 87-130.

ESA. AGÊNCIA ESPACIAL EUROPEIA (ESA). **Introduzindo o Sentinel-2**. Disponível em:

<https://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel2/Introducing_Sentinel-2>. Acesso em: 17/03/2020.

FEITOSA, A. C.; TROVÃO, J. R. **Atlas escolar do Maranhão: espaço geohistórico e cultural**. João Pessoa: Editora Grafset, 2006.

FLORENZANO, T. G. **Imagens de Satélite para Estudos Ambientais**. São Paulo, SP: Oficina De Textos, 2002, 100 p.

FREIRES, E. V.; da SILVA NETO, C. Â.; CUNHA, D. S. R.; DUARTE, C. R.; VERÍSSIMO, C. U. V.; GOMES, D. D. M. Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará. **Anuário do Instituto de Geociências**, 42(4), 2020. p. 427-442.

GIONGO, P. R.; MOURA, G. B. A.; RÊGO, P. L.; MEDEIROS, S. R. R. **Índices de vegetação NDVI, SAVI e IAF estimados com imagens Landsat 5 –TM**. VII Jornada de Ensino, Pesquisa e Extensão, Recife. 2007.

HUETE, A. R. Adjusting vegetation indices for soil influences. **International Agrophysics**, vol. 4, no. 4, 1988. pp. 367-376.

INMET. Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=clima/normaisClimatologicas>>. Acessado em: 12 de abril de 2020.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres**. Tradução de J. C. N. Epiphânio. Ed. Parênteses, São José dos Campos, SP. 2011.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução: EPIPHANIO, J. C. N. São José dos Campos: Parêntese, 2009. 598 p. Tradução de Remote sensing of the environment: na Earth resource perspective.

LANDIS, J. R; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, 33(1): 159-174. 1977.

LIANG, Shunlin; FANG, Hongliang; CHEN, Mingzhen. Atmospheric correction of Landsat ETM+ land surface imagery. I. Methods. **IEEE Transactions on geoscience and remote sensing**, v. 39, n. 11, p. 2490-2498, 2001.

MACHADO, C.; OLIVEIRA, T. H.; GALVÍNCIO, J. D. **Variação do IVAS e da Temperatura à superfície na bacia hidrográfica do rio Capibaribe –PE utilizando imagens do satélite Landsat 5 TM**. XII Congresso Nordestino de Ecologia, Gravatá. 2009.

MAGALHÃES, I. A. L.; CARVALHO JUNIOR, O. A.; SANTOS, A. R. Análise comparativa entre técnicas de sensoriamento remoto para mensuração da vegetação urbana no município de Alegre, ES. **Revista Cerrados**, v.15, n.1, p.156-177, 2017.

MARANHÃO, Gerência de Planejamento e Desenvolvimento Econômico, laboratório de geoprocessamento - UEMA. **Atlas do Maranhão**, São Luís: GEPLAN, 2002.

MARANHÃO. Secretaria de Estado do Meio Ambiente e Recursos Naturais. **Diagnóstico para a implementação do Plano de Ação para a Prevenção e Controle do Desmatamento e das Queimadas no Maranhão - PPCD-MA**. SEMA. Brasília. 2011.

MARINO, S.; ALVINO, A. Agronomic Traits Analysis of Ten Winter Wheat Cultivars Clustered by UAV-Derived Vegetation Indices. **Remote Sensing**, v. 12, n. 2, p. 249, 2020.

MATHER, P. **Computer Processing of Remotely-Sensed Images**. John Wiley & Sons, Chichester, UK, 1999.

MOREIRA, M. A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 1.ed. São José dos Campos: INPE, 2001. 250 p.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 3 ed. UFV, Minas Gerais, 2007. pp. 320.

NOVACK, T. **Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor QuickBird**. 2009. 214 p. (INPE-16594-TDI/1580). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: Acesso em: 01 out. 2018.

OLIVEIRA, L. N.; AQUINO, C. M. S.; Dinâmica Temporal Do Uso E Cobertura Da Terra Na Fronteira Agrícola Do Matopiba: análise na sub-bacia hidrográfica do rio Gurguéia-Piauí. **Revista Equador**, v. 9, n. 1, p. 317-333, 2019.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da vegetação**. 2 Ed. São Paulo, Oficina de Textos, 2012. 164p.

PRATES, Izabela. **Utilização de imagens LANDSAT-8 para caracterização da cobertura vegetal**. Disponível em <<https://mundogeo.com/blog/2014/06/10/processamento-digital-de-imagens-landsat-8-para-obtencao-dos-indices-de-vegetacao-ndvi-e-savi-visando-a-caracterizacao-da-cobertura-vegetal-no-municipio-de-nova-lima-mg/>>. Acesso em 10 de abril de 2020.

RIBEIRO, G. A.; DE CASTRO SILVA, J. N.; DA SILVA, J. B. Índice de Vegetação Ajustado ao Solo (IVAS): estado da arte e suas potencialidades. **Revista Brasileira de Geografia Física**, v. 9, n. 06, p. 2054-2074, 2016.

RIBEIRO, R. P.; ALVES, P. R.; ALMEIDA, Z. D. S.; RUTA, C. A new species of Paraonis and an annotated checklist of polychaetes from mangroves of the Brazilian Amazon Coast (Annelida, Paraonidae). **ZooKeys**, (740), 1. 2018.

RICHTER, Rudolf. A spatially adaptive fast atmospheric correction algorithm. **International Journal of Remote Sensing**, v. 17, n. 6, p. 1201-1214, 1996.

RODRIGUES, T. C. S. **Classificação da Cobertura e do Uso da Terra com Imagens Worldview-2 de Setores Norte da Ilha do Maranhão por Meio do Aplicativo Interimage e de Mineração de Dados**. 2014. 87 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

RODRIGUES, T. C. S. **Estudo da cobertura e uso da terra na microrregião do Gurupi, Amazônia maranhense, entre os anos 1976-2016 por meio da aplicação do sensoriamento remoto e SIG's**. 2018. 183f. Tese (Doutorado em Geografia), Universidade Estadual Paulista "Júlio de Mesquita Filho" UNESP/FCT - Campus de Presidente Prudente, São Paulo, 2018.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. **Monitoring vegetation systems in the Great Plains with ERTS**. In Earth Resources Technology Satellite- 1 Symposium, 3, 1973. Proceedings. Washington, 1973, v.1, Sec. A, p. 309-317.

SERRA, J. S.; FILHO, M. S. F. Expansão urbana e impactos ambientais na zona costeira norte do município de São Luís (MA). **Raega-O Espaço Geográfico em Análise**, v. 46, n. 1, p. 25-40, 2019.

SILVA, L.G.; GALVÍNCIO, J. D. Análise comparativa da variação dos índices NDV e SAVI no sítio PELD -22 em Petrolina – PE, na primeira década do século XXI. **Revista Brasileira de Geografia Física** 06, 2012. 1446-1456.

SOUSA, E. B; COSTA, V. B.; PEREIRA, L. C. C.; COSTA R. M. Microfitoplâncton de águas costeiras amazônicas: ilha Canela (Bragança, PA, Brasil). **Acta Botanica Brasilica**, 22: 626–636. 2008.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, 52(3):397-399. 1986.

USGS, 2018. **United States Geological Survey**. *Em:* < <http://earthexplorer.usgs.gov/>>. Acesso em: 17/03/2020.

VASCONCELOS, C. H.; NOVO, E. M. L. de M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens-fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor TM/Landsat5, na região do reservatório de Tucuruí-PA. **Acta Amazônica**, v. 34, n. 3, p. 487-493, 2004.

WALD, L.; RANCHIN, T.; MANGOLINI, M. Fusion of satellite images of different spatial resolutions: assessing the quality of resulting images. **Photogrammetric Engineering & Remote Sensing**, v. 63, n. 6, pp. 691-699, 1997.

AGRADECIMENTOS

O autor agradece a Universidade Federal do Maranhão por todo suporte e infraestrutura disponibilizada, à Coordenação do Curso de Engenharia de Pesca da Universidade Federal do Maranhão do Campus Pinheiro pelo apoio. Um agradecimento especial aos revisores anônimos que fizeram excelentes críticas e sugestões construtivas que ajudaram a elevar a qualidade científica do artigo.