



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA
CURSO DE GRADUAÇÃO EM ENGENHARIA CARTOGRÁFICA E DE
AGRIMENSURA

VINÍCIUS D'LUCAS BEZERRA E QUEIROZ

**ANÁLISE COMPARATIVA ENTRE OS ALGORITMOS MÁXIMA
VEROSSIMILHANÇA E RANDOM FOREST: CLASSIFICAÇÃO DOS BOSQUES
DE MANGUE DA ÁREA DE PROTEÇÃO AMBIENTAL DE SANTA CRUZ,
PERNAMBUCO, BRASIL**

Recife

2021

VINÍCIUS D'LUCAS BEZERRA E QUEIROZ

**ANÁLISE COMPARATIVA ENTRE OS ALGORITMOS MÁXIMA
VEROSSIMILHANÇA E RANDOM FOREST: CLASSIFICAÇÃO DOS BOSQUES DE
MANGUE DA ÁREA DE PROTEÇÃO AMBIENTAL DE SANTA CRUZ,
PERNAMBUCO, BRASIL**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito para a obtenção do título de Bacharel em Engenharia Cartográfica e de Agrimensura.

Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias

Recife

2021

Catálogo na fonte
Bibliotecário Gabriel Luz CRB-4 / 2222

- Q3a Queiroz, Vinícius D'Lucas Bezerra e.
Análise comparativa entre os algoritmos máxima verossimilhança e random forest: classificação dos bosques de mangue da área de proteção ambiental de Santa Cruz, Pernambuco, Brasil / Vinícius D'Lucas Bezerra e Queiroz. 2021.
104 f.; figs., tabs., quadros., abrev. e siglas.
- Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.
TCC (Graduação) – Universidade Federal de Pernambuco. CTG.
Departamento de Engenharia Cartográfica, Recife, 2021.
Inclui referências e apêndices.
1. Ciências Geodésicas. 2. Máxima verossimilhança. 3. Random forest. 4. Mangue. 5. Processamento de imagens. I. Candeias, Ana Lúcia Bezerra (Orientadora). II. Título.
- UFPE
- 526.1 CDD (22. ed.) BCTG / 2022-61

VINÍCIUS D'LUCAS BEZERRA E QUEIROZ

**ANÁLISE COMPARATIVA ENTRE OS ALGORITMOS MÁXIMA
VEROSSIMILHANÇA E RANDOM FOREST: CLASSIFICAÇÃO DOS BOSQUES DE
MANGUE DA ÁREA DE PROTEÇÃO AMBIENTAL DE SANTA CRUZ,
PERNAMBUCO, BRASIL**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito para a obtenção do título de Bacharel em Engenharia Cartográfica e de Agrimensura.

Aprovada em: 20 / 04 / 2021

BANCA EXAMINADORA

Profa. Dra. Ana Lúcia Bezerra Candeias (Orientadora)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. João Rodrigues Tavares Júnior (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Profa. Dra. Evlyn Marcia Leão de Moraes Novo (Examinadora Externa)
Instituto Nacional de Pesquisas Espaciais - INPE

Profa. Dra. Maycira Costa (Examinadora Externa)
University of Victoria - UVic

Dedico esse trabalho a Vanildo Pereira de Queiroz (*In Memoriam*)

AGRADECIMENTOS

Agradeço, primeiramente, aos meus pais Vanildo Jr. e Maria de Fátima por todo suporte e apoio incondicional durante o curso de Engenharia Cartográfica e de Agrimensura.

Agradeço a minha namorada Yasmim Menezes pela ajuda, apoio, carinho, companheirismo, atenção e principalmente paciência, durante minha jornada acadêmica.

Agradeço a minha professora orientadora Dra. Ana Lúcia Bezerra Candeias por sua orientação, ensinamentos, apoio e paciência durante todos nossos projetos e, especialmente, na elaboração deste trabalho.

Agradeço também ao amigo/irmão Maike Menezes pela ajuda na tradução e apoio.

Agradeço a Ivo Raposo pela ajuda, conselhos e dicas valiosas que me ajudaram a concluir este trabalho.

Um agradecimento adicional a Marcos Lacerda da CPRH pela gentileza de ter fornecido os dados vetoriais utilizados nesse trabalho.

|
|

RESUMO

Este trabalho visa avaliar a acurácia dos classificadores supervisionados pixel-a-pixel Máxima Verossimilhança (MaxVer) e o *Random Forest* (RF) e o efeito da combinação de diferentes dados de entrada na classificação de bosques de mangue da Área de Proteção Ambiental (APA) de Santa Cruz no Estado de Pernambuco. A escolha deste alvo como objeto de classificação está relacionada com o seu valor ambiental e socioeconômico, assim como a sua fragilidade referente à pressão antrópica. Para a avaliação do desempenho da classificação de cada um desses algoritmos, foram construídos 4 (quatro) *bandsets* de classificação combinando uma imagem de sensor óptico (Landsat-5/TM) com índices de vegetação (NDVI, SAVI e NDWI) e imagens de Radar de Abertura Sintética (ALOS/PALSAR). Por meio da matriz de erro obtida em cada classificação e das métricas de acurácia geradas a partir dela, foi possível verificar o efeito da inclusão de dados de entrada na acurácia da classificação de bosques de mangue. Os resultados obtidos mostram que utilizando apenas bandas da imagem óptica o desempenho dos dois classificadores foi semelhante, em torno de 96% de acurácia global – classificados como desempenho “muito bom” pelo índice kappa – gerando áreas classificadas semelhantes as adquiridas pelo MapBiomias. Entretanto, observou-se a diminuição da acurácia de classificação do MaxVer quando foram introduzidos mais dados de entrada e de fontes diferentes. Já o *Random Forest* obteve acurácia global acima de 95% em todas as classificações, alcançando seu valor máximo quando utilizadas todas as bandas de entrada (*bandset 4*). Além disso, este classificador apontou, dentre as bandas utilizadas, o SWIR 1 e os índices de vegetação como variáveis de maior importância na classificação.

Palavras-chave: máxima verossimilhança; random forest; mangue; processamento de imagens.

ABSTRACT

This paper aims to evaluate the accuracy of the pixel-to-pixel supervised classifiers Maximum Likelihood (MaxVer) and Random Forest (RF) and the effect of combining different input data in the classification of mangrove forests of the Environmental Protection Area of Santa Cruz in the State of Pernambuco. The choice of this target as a classification object is connected to its environmental and social-economical value, as well as its vulnerability regarding the anthropic pressure. For the performance evaluation of each one of the algorithms, 4 (four) classification bandsets were created with image combinations from optic sensors (Landsat-5/TM) with vegetation indexes (NDVI, SAVI, NDWI) and Synthetic Aperture Radar (ALOS/PALSAR) images. Through the error matrix obtained in each classification and the accuracy metrics generated from it, it was possible to verify the effect of including input data on the accuracy of the mangrove forest classification. The results obtained show that using only optic images (bandset 1) the performance of both classifiers was similar, around 96% of global accuracy - classified as "very good" by the Kappa index - generating classified areas similar to those acquired by MapBiomas. However, a decrease in the accuracy of the MaxVer classification was noticed as more data entries from different sources were introduced. On the other hand, Random Forest obtained a global accuracy above 95% in all classifications, reaching its maximum value when all input bands were used (bandset 4). Additionally, these classifiers pointed, among other bands used, the SWIR 1 and vegetation indexes as the most important on the classification.

Keywords: maximum likelihood; random forest; mangrove forests; image processing.

LISTA DE FIGURAS

Figura 1 - Assinatura espectral da água, do solo e da vegetação desde a faixa do visível até o infravermelho de ondas curtas (0,4 - 2,5 μm).....	22
Figura 2 - Distribuição do ecossistema manguezal no mundo (em verde).....	23
Figura 3 - Distribuição dos manguezais no litoral brasileiro.....	24
Figura 4 - Feições do manguezal. (a) Bosque de mangue e área de lavado; (b) Apicum; (c) bosque de mangue, rizóforos característicos da espécie <i>R. mangle</i>	25
Figura 5 - Evolução das aplicações de sensoriamento remoto em manguezais.....	28
Figura 6 - Assinatura espectral característica de uma folha verde	30
Figura 7 - Reflectância média de duas espécies de mangue identificadas na Baía de Vitória (ES).....	32
Figura 8 - Principais mecanismos de espalhamento considerado para dados SAR.....	36
Figura 9 - Principais mecanismos de espalhamento relacionados aos componentes do manguezal	37
Figura 10 - Modelo do Random Forest.....	41
Figura 11 - Fluxograma da metodologia abordada.....	50
Figura 12 - Mapa de localização da área de estudo	51
Figura 13 - APA de Santa Cruz	53
Figura 14 - UAH 5 (em verde) sobre composição colorida falsa cor RGB453, realçando a vegetação existente nos manguezais.....	54
Figura 15 - Uso e cobertura do solo da Aapa de Santa Cruz utilizando dados do Mapbiomas..	58
Figura 16 - Seleção da classe "mangue" (à direita) em relação as classes de uso e cobertura da APA de Santa Cruz - 2010 (à esquerda)	59
Figura 17 - Composições coloridas geradas a partir do empilhamento das bandas dos sensores TM e PALSAR.....	61
Figura 18 - Recorte da área de estudo utilizado para classificação	62
Figura 19 - NDVI da área de estudo	64
Figura 20 - NDWI da área de estudo	64
Figura 21 - SAVI da área de estudo.....	65
Figura 22 - Espacialização das amostras de treinamento por classe.....	67
Figura 23 - Painel de classificação do MaxVer no SCP	69
Figura 24 - Painel de classificação do Random Forest no SCP.....	70

Figura 25 - Espacialização do vetor referente a UAH 5 e divergências entre o vetor e a imagem.....	Destino não encontrado!
Figura 26 - Espacialização das amostras de validação no Google Earth Pro	72
Figura 27 - Aquisição de amostras de avaliação no Google Earth Pro utilizando a série histórica.....	72
Figura 28 - Painel de avaliação de acurácia do SCP.....	73
Figura 29 - Resultado da classificação do bandset 1 utilizando os classificadores Máxima Verossimilhança e Random Forest.	74
Figura 30 - Resultado da classificação do bandset 2 utilizando os classificadores Máxima Verossimilhança e Random Forest.	76
Figura 31 - Resultado da classificação do bandset 3 utilizando os classificadores Máxima Verossimilhança e Random Forest	Destino não encontrado!
Figura 32 - Resultado da classificação do bandset 4 utilizando os classificadores Máxima Verossimilhança e Random Forest	81
Figura 33 - Gráfico da comparação entre as áreas geradas pela classificação dos bandsets por Máxima Verossimilhança e Random Forest	85



LISTA DE TABELAS

Tabela 1 - Exemplo matemático de uma matriz de erro	43
Tabela 2 - Exemplo matemático de uma matriz de erro baseada em proporção de área	45
Tabela 3 - Agrupamento qualitativo de valores de kappa	48
Tabela 4 - Definição dos bandsets para classificação	59
Tabela 5 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 1 por MaxVer	75
Tabela 6 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 1 por Random Forest	75
Tabela 7 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 2 por MaxVer	77
Tabela 8 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 2 por Random Forest	77
Tabela 9 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 3 por MaxVer	Destino não encontrado!
Tabela 10 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 3 por Random Forest	80
Tabela 11 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 4 por MaxVer	82
Tabela 12 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 4 por Random Forest	82
Tabela 13 - Resumo das principais estatísticas de avaliação de acurácia para as classificações	83
Tabela 14 - Áreas classificadas como mangue em cada classificação e a diferença	84
Tabela 15 - Diferença entre as áreas calculadas e a área da classe mangue do Mapbiomas (2010)	Destino não encontrado!

LISTA DE QUADROS

Quadro 1 - Principais bandas utilizadas no sensoriamento remoto por SARDestino não encontrado!	
Quadro 2 - Principais características da imagem Landsat-5/TM utilizada.....	55
Quadro 3 - Principais características da primeira imagem ALOS/PALSAR utilizada.....	56
Quadro 4 - Principais características da segunda imagem ALOS/PALSAR utilizada.....	56
Quadro 5 - Definição e descrição das classes para classificação.....	66
Quadro 6 - Quantidade de amostras (pixels) por classe.....Destino não encontrado!	
Quadro 7 - Ranking de relevância das variáveis na classificação por Random ForestDestino não encontrado!	

LISTA DE ABREVIATURAS E SIGLAS

ALOS	<i>Advanced Land Observing Satellite</i>
ASF	<i>Alaska Satellite facilities</i>
CPRH	Agência Estadual de Meio Ambiente de Pernambuco
DHN	Diretoria de Hidrografia e Navegação
FADURPE	Fundação Apolônio Salles de Desenvolvimento Educacional
GIS	<i>Geographic Information System</i>
IC	Intervalo de Confiança
LAI	<i>Leaf Area Index</i>
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
LIDAR	<i>Light Detection And Ranging</i>
Mapbiomas	Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil
MaxVer	Máxima Verossimilhança
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDMI	<i>Normalized Difference Moisture Index</i>
NDWI	<i>Normalized Difference Water Index</i>
OA	<i>Overall Accuracy</i> (Acurácia Global)
OLI	<i>Operational Land Imager</i>
PA	<i>Producer's Accuracy</i> (Acurácia do Produtor)
PALSAR	<i>Phased Array L-band Synthetic Aperture Radar</i>
PDI	Processamento Digital de Imagem
RADAR	<i>Radio Detection and Ranging</i>
RF	<i>Random Forest</i>
RTC	<i>Radiometric Terrain Corrected</i>
RVS	Refúgio da Vida Silvestre
SAR	<i>Synthetic Aperture Radar</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SCP	<i>Semi Automatic Classification Plugin</i>
SR	Sensoriamento Remoto
SWIR	<i>Short Wave Infrared</i>
UA	<i>User's Accuracy</i> (Acurácia do Usuário)
UAH	Unidades Ambientais Homogêneas
UC	Unidade de Conservação
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>
VIM	<i>Variable Importance Measures</i>

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	18
2.1	OBJETIVO GERAL.....	18
2.2	OBJETIVOS ESPECÍFICOS	18
3	REFERENCIAL TEÓRICO	19
3.1	SENSORIAMENTO REMOTO	19
3.2	ECOSSISTEMA MANGUEZAL	23
3.3	SENSORIAMENTO REMOTO APLICADO A DETECÇÃO DE MANGUEZAIS	27
3.3.1	Características dos bosques de mangue em imagens ópticas	29
3.3.2	Características dos bosques de mangue em imagens SAR	34
3.4	CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS	38
3.4.1	Máxima Verossimilhança (MaxVer)	39
3.4.2	Random Forest (RF)	40
3.5	ANÁLISE DA ACURÁCIA DE CLASSIFICAÇÕES.....	42
3.5.1	Matriz de erro	43
3.5.2	Índice Kappa	47
4	METODOLOGIA	49
4.1	ÁREA DE ESTUDO	50
4.2	AQUISIÇÃO DE DADOS	54
4.3	PRÉ-PROCESSAMENTO	58
4.3.1	Conversão Radiométrica	58
4.3.2	Geoprocessamento	59
4.3.3	Cálculo dos índices físicos	60
4.3.4	Definição dos bandsets de classificação	62
4.4	CLASSIFICAÇÃO SUPERVISIONADA	65
4.4.1	Definição das classes	66
4.4.2	Amostragem	66
4.4.3	Máxima Verossimilhança	68
4.4.4	Random Forest	69
4.5	AVALIAÇÃO DA ACURÁCIA DAS CLASSIFICAÇÕES.....	70
4.5.1	Aquisição de amostras de avaliação	70
4.5.2	Estatísticas de Avaliação	73

5	RESULTADOS E DISCUSSÕES	74
5.1	CLASSIFICAÇÕES DO BANDSET 1	74
5.2	CLASSIFICAÇÕES DO BANDSET 2.....	76
5.3	CLASSIFICAÇÕES DO BANDSET 3.....	78
5.4	CLASSIFICAÇÕES DO BANDSET 4.....	81
5.5	RESUMO DOS RESULTADOS ESTATÍSTICOS DAS CLASSIFICAÇÕES.....	83
6	CONSIDERAÇÕES FINAIS.....	88
	REFERÊNCIAS	90
	APÊNDICE A – CLASSIFICAÇÕES DO BANDSET 1 (TM).....	101
	APÊNDICE B – CLASSIFICAÇÕES DO BANDSET 2 (TM + SAR).....	102
	APÊNDICE C - CLASSIFICAÇÕES DO BANDSET 3 (TM + ÍNDICES).....	103
	APÊNDICE D - CLASSIFICAÇÕES DO BANDSET 4 (TM + SAR + ÍNDICES	104

1 INTRODUÇÃO

O mapeamento do ecossistema manguezal é importante devido ao seu valor ambiental e socioeconômico. Este ecossistema desempenha papel de exportador de matéria orgânica para os estuários, retém sedimentos e serve como berço e refúgio para várias espécies de animais (CARVALHO et al., 2015). Além disso, seu valor socioeconômico está relacionado com as comunidades que tiram seu sustento por meio da pesca artesanal e de subsistência (SILVA, 2006).

Uma das feições existentes no manguezal são os bosques de mangue, que são árvores características do ecossistema. Essa vegetação aprisiona sedimentos entre suas raízes e troncos (além de poluentes, prevenindo contaminação das águas), atenua efeitos de tempestades (protegendo a linha de costa), transforma nutrientes minerais em matéria orgânica vegetal, representando importante produtor primário do ambiente marinho e gerando bens e serviços para as comunidades (SCHAEFFER-NOVELLI, 2018b).

Em contraste com sua importância, os manguezais são ambientes vulneráveis. Sofrem grande pressão antrópica relacionada a ocupação irregular, desmatamento, poluição das águas por esgotos domésticos e industriais. Esses problemas, segundo o ICMbio (2018, pg. 8), “causam a diminuição na oferta de recursos dos quais muitas comunidades tradicionais e setores dependem diretamente para sobreviver”. O ICMBio (op. cit.), ainda afirma que, “estima-se que aproximadamente 25% desse ecossistema já tenha se perdido no país, devido principalmente à carcinicultura e ao desenvolvimento costeiro inadequado”.

Devido à sua relevância e fragilidade, verifica-se a importância do uso de técnicas que tenham a finalidade de monitorar esse ecossistema (ARAÚJO, 2010). Assim, as imagens de sensoriamento remoto podem ser um recurso para adquirir informações sobre esse ambiente, permitindo auxílio na tomada de decisão para mitigações de problemas e gerenciamento ambiental.

As informações provenientes de imagens Sensoriamento Remoto podem ser extraídas por meio de diversas técnicas de processamento de imagens e, devido ao desenvolvido tecnológico, dados de vários sistemas/sensores estão disponíveis para utilização, alguns deles de forma gratuita. Portanto, a escolha do sensor apropriado juntamente a técnica utilizada para a extração de informações de imagens irá depender dos objetivos do estudo e dos recursos disponíveis para tal (GREEN, 1998).

Dentre os métodos de extração de informação utilizando imagens de Sensoriamento Remoto, a classificação supervisionada é uma das técnicas principais e mais utilizadas pois

leva em consideração o conhecimento do analista sobre a região a ser estudada. Como existem vários algoritmos de classificação, é necessário que o analista tenha conhecimento de suas características, particularidades e possibilidades de aplicação, pois diferentes dados de entrada (imagens), amostras e parâmetros escolhidos podem gerar resultados diferentes e, conseqüentemente, classes temáticas com áreas e localizações discrepantes.

Em relação a esta abordagem, como verificar se o algoritmo de classificação escolhido gerou um resultado acurado e que represente bem a verdade terrestre? Para Green (1998), a avaliação da acurácia da classificação é o critério que deve ser usado para julgar o sucesso de um método de processamento de imagens. Uma das formas comumente usadas de verificar isso é por meio da matriz de erro (ou matriz de confusão), pois a partir dela é possível extrair métricas de avaliação que quantificam o resultado das classificações como acurácia global, acurácia do produtor, acurácia do usuário e a estimativa do índice kappa.

Na literatura, um dos classificadores supervisionados mais utilizados com imagens de sensores ópticos é o Máxima Verossimilhança (MaxVer) e isso também ocorre para aplicações relacionadas a mapeamento de manguezais (KUENZER et al., 2011). Esse classificador foi desenvolvido supondo que os dados amostrados possuam distribuição de probabilidade gaussiana. Entretanto, quando esse pressuposto não é cumprido pela distribuição das classes, há a redução da acurácia de classificação.

Outros classificadores mais robustos que o MaxVer têm sido desenvolvidos para suprir a necessidade de mapeamentos mais precisos em relação a alvos complexos da superfície terrestre (Rodriguez-Galiano et al., 2012). Um deles é o *Random Forest*, que por ser um classificador não-paramétrico, não assume a priori a distribuição de probabilidade dos dados, permitindo a integração de grandes conjuntos de diversas fontes. Trabalhos envolvendo mapeamento de manguezais utilizando este classificador mostram a integração de imagens de Radar de Abertura Sintética (SAR) com imagens ópticas, abordando melhora na acurácia da classificação em relação a outros tipos de classificadores (ABDEL-HAMID et al., 2017; JHONNERIE et al., 2015).

Mediante a isso, este trabalho se propõe a comparar a acurácia de classificação de áreas de mangue por meio dos classificadores supervisionados Máxima Verossimilhança e *Random Forest* e verificar o efeito que a combinação de diferentes tipos de dados de entrada (imagem óptica, imagem de radar de abertura sintética e índices físicos) causa na classificação. A partir da matriz de erro gerada em cada uma das classificações é possível comparar qual dessas classificações apresenta melhores métricas de avaliação de acurácia e, portanto, tem maior confiabilidade e qualidade.

Dentro de todo esse contexto, a compreensão de todas essas características é um aspecto importante na engenharia cartográfica no que diz respeito a geração de informações precisas e que, de fato, representem a verdade terrestre. A escolha dos métodos mais adequados e a avaliação dos resultados garante a qualidade do produto gerado e a confiabilidade do usuário no uso dessas informações, permitindo que possam ser utilizados como base em estudos multidisciplinares a partir de representações cartográficas.

2 OBJETIVOS

Os objetivos geral e específicos do trabalho são apresentados nesta seção.

2.1 OBJETIVO GERAL

Avaliar a acurácia da classificação de bosques de mangue na Área de Proteção Ambiental de Santa Cruz, Pernambuco, Brasil utilizando os classificadores Máxima Verossimilhança e *Random Forest*.

2.2 OBJETIVOS ESPECÍFICOS

- a) Testar o impacto de 4 conjuntos distintos de dados de entrada sobre a acurácia da classificação;
- b) Observar quais bandas foram mais significativas para a classificação de bosques de mangue;
- c) Quantificar as áreas de mangue classificadas e comparar com os dados obtidos pelo MapBiomas.

3 REFERENCIAL TEÓRICO

Nessa seção apresenta-se o embasamento teórico que respalda este estudo e envolve as seções: 3.1 Sensoriamento Remoto, 3.2 Ecossistema Manguezal, 3.3 Sensoriamento Remoto Aplicado a Detecção de Manguezais, 3.4 Classificação Automática de Imagens e 3.5 Análise da Acurácia de Classificações.

3.1 SENSORIAMENTO REMOTO

O Sensoriamento Remoto (SR) é a arte e a ciência de obter informações sobre um objeto sem estar em contato físico direto com ele, entretanto, esta definição é proposta de forma genérica, abrangendo todos os dispositivos de aquisição de informações de forma remota como por exemplo: câmeras, scanners, dispositivos imageadores lineares ou matriciais, sistemas de radar, sonares, sismógrafos, gravímetros e magnetômetros (Jensen, 2009). Por este motivo, esta definição foi modificada ao longo tempo, sendo possível encontrar na literatura outras definições mais específicas e modernas como em Centeno (2004), Jensen (2009), Novo (2010), Menezes e Almeida (2012) e Zanotta, Ferreira e Zortea (2019).

Desta forma, Novo (2010) propõe Sensoriamento Remoto como

A utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados colocados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que o compõem em suas mais diversas manifestações (NOVO, 2010, p.28).

Essa ciência tem origem nos anos de 1960 devido ao progresso da área espacial, período chamado de “corrida espacial”. Nesta época houve rápido desenvolvimento de foguetes lançadores de satélites que possibilitou colocar no espaço satélites artificiais que inicialmente tiveram finalidades meteorológicas. Com o passar dos anos e o lançamento de diversos outros sistemas imageadores, as imagens de satélites foram utilizadas em outros objetivos como levantamentos de recursos naturais e mapeamentos temáticos, monitoração ambiental, detecção de desastres naturais, desmatamentos florestais, previsões de safras, cadastramentos multifinalitários, cartografia de precisão, defesa e vigilância, entre outras (MENESES; ALMEIDA, 2012).

A capacidade de aquisição de imagens em intervalos regulares de tempo e a cobertura de grandes áreas faz do SR uma grande ferramenta para obtenção de informações sobre o meio ambiente, constituindo uma fonte contínua de dados (ZANOTTA; FERREIRA; ZORTEA, 2019). Esta característica permite uma avaliação dinâmica e estratégica do uso e ocupação do solo que sofre mudanças significativas devido à atividade humana (RIBEIRO; FONSECA, 2013).

Ribeiro e Fonseca (2013) abordam também o crescente uso do sensoriamento remoto em áreas urbanas devido às suas diversas aplicações como as relacionadas ao planejamento urbano, mudanças climáticas e meio ambiente. Aplicações como estas, tornaram-se possíveis devido ao avanço da tecnologia, que proporcionou o desenvolvimento de sistemas sensores com melhores resoluções e que permitem a detecção dos elementos que compõem o espaço intraurbano e apresentando aplicabilidade para mapeamento de cobertura do solo (PINHO, 2005).

A extração de informações dos objetos na superfície terrestre a partir do sensoriamento remoto acontece por meio da interação do objeto com a energia eletromagnética. Segundo Centeno (2004), esta energia pode ser: (a) emitida por uma fonte natural e refletida pela superfície do objeto; (b) emitida pelo objeto; e (c) emitida artificialmente em direção ao objeto e refletida pela superfície do objeto.

A partir disto, os sensores remotos podem ser categorizados em passivos e ativos. Os sensores passivos são aqueles que captam a radiação eletromagnética proveniente do Sol refletida pelos objetos na superfície terrestre ou da emissão de radiação da Terra. Os sensores que atuam nas faixas do espectro eletromagnético do visível, do infravermelho próximo e do infravermelho médio são chamados de sensores ópticos, possuindo espelhos, prismas e lentes em suas configurações (NOVO, 2010). Têm-se como exemplo de sensores passivos os sensores multiespectrais a bordo de diversos satélites como o *Operational Land Imager* (OLI) a bordo do satélite Landsat 8 e a *Moderate Resolution Imaging Spectroradiometer* (MODIS), a bordo dos satélites TERRA e AQUA (SHIRATSUCHI et al., 2014).

Já os sensores ativos não dependem de uma fonte de radiação externa e produzem sua própria fonte de iluminação, ou seja, eles captam o retroespalhamento da energia artificial produzida pela própria plataforma (ZANOTTA; FERREIRA; ZORTEA, 2019). É através da medição dessa energia, por meio de uma antena, que os dados são gravados. Têm-se como exemplos deste tipo de sensor o Radar (do inglês *Radio Detection and Ranging*) e o Lidar (do inglês *Light Detection and Ranging*).

A energia registrada pelos sensores depende da interação com a atmosfera e depois com os materiais existentes na superfície terrestre. Os processos de interação com os constituintes atmosféricos são o espalhamento e absorção atmosféricos que interferem na quantidade de energia que chega ao sensor. Estes processos podem ser observados com mais detalhes em Jensen (2009), Centeno (2004), Novo (2010) e Zanotta, Ferreira e Zortea (2019).

Depois da interação com a atmosfera, o fluxo incidente interage com o material propriamente dito. Uma parte deste fluxo é absorvido pelo material, outra parte é refletida e por fim outra parte é transmitida. A intensidade desses processos varia com a composição química de cada alvo e do comprimento de onda da radiação incidente. Assim, a interação do fluxo incidente de energia (ϕ) com o material pode ser expressa em função da reflexão, absorção e transmissão (CENTENO, 2004), como mostra a equação 1, também conhecida como balanço de energia.

$$\phi_{incidente} = \phi_{refletido} + \phi_{absorvido} + \phi_{transmitido} \quad (1)$$

Dividindo toda esta equação por $\phi_{incidente}$, tem-se o balanço de energia expresso em termos relativos adimensionais, variando de 0 a 1, que são geralmente expressos em termos percentuais (equação 2).

$$1 = \rho + \sigma + \tau \quad (2)$$

Onde:

ρ = refletância;

σ = absortância;

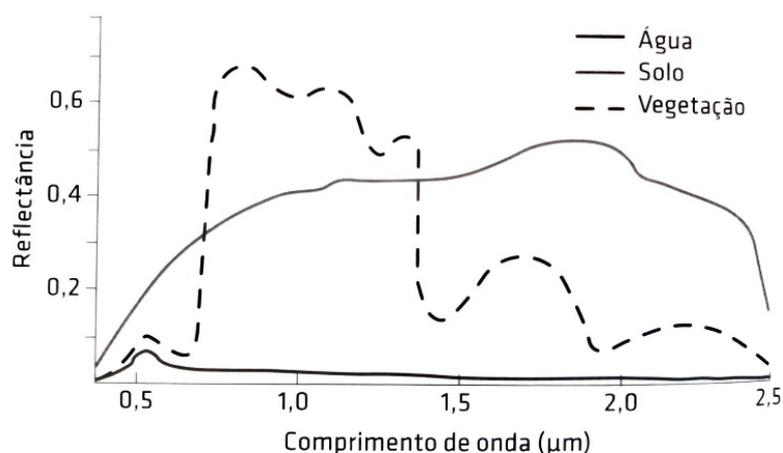
τ = transmitância.

Como dito anteriormente, a intensidade destes processos também varia em relação ao comprimento de onda (λ), logo, é mais apropriado descrever esse balanço de energia em função dele. Os termos passam então a se chamar reflectância espectral (ρ_λ), absortância espectral (σ_λ), e transmitância espectral (τ_λ) (CENTENO, 2004).

A porção do fluxo de energia incidente que chega ao sensor está relacionada a quantidade de energia refletida pelo objeto. A partir deste valor, é possível calcular a reflectância espectral de um determinado material, ou seja, a sua reflectância por comprimento de onda. Os valores de refletância quando plotados num gráfico dão origem ao

chamado “comportamento espectral” ou “assinatura espectral” do material. Na figura 1, pode ser visto o comportamento espectral dos principais alvos presentes na superfície terrestre.

Figura 1 - Assinatura espectral da água, do solo e da vegetação desde a faixa do visível até o infravermelho de ondas curtas (0,4 - 2,5 μm)



Fonte: Zanotta, Ferreira e Zortea, 2019.

A reflectância é, portanto, um parâmetro essencial na interpretação de imagens pois é utilizada para identificar espectralmente os materiais terrestres como solos, vegetação, corpos de água, alvos urbanos, rochas, entre outros (MENESES; ALMEIDA; BAPTISTA, 2019).

Assim como as características espectrais dos materiais, é importante também levar em consideração as especificações dos sensores na hora da escolha para determinada aplicação. As principais características a serem observadas são as resoluções, que são divididas em: resolução espacial, espectral, radiométrica e temporal. Zanotta, Ferreira e Zortea (2019) afirmam que nem sempre é possível contar com as melhores resoluções em um único instrumento, pois cada sensor é projetado com configurações para atender a alguma aplicação em especial.

A resolução espacial está relacionada com a capacidade do sensor em distinguir elementos na superfície terrestre, ou seja, é a representação do menor objeto possível a ser detectado pelo sensor. Já a resolução espectral está relacionada com a largura e quantidade de faixas espectrais contidas no instrumento, caracterizando a capacidade de descrever o comportamento espectral dos alvos. A resolução radiométrica está relacionada com a capacidade do sensor de registrar as variações da energia em níveis de cinza. Por fim, a resolução temporal é o tempo que o sensor leva para revisitar e registrar informações de uma mesma área.

Esses conceitos podem ser vistos com mais profundidade por meio das referências supracitadas. Entretanto, é de suma importância o conhecimento deles para a tomada de decisão na escolha do sensor utilizado para a aplicação desejada. Como dito, cada sensor é projetado para atender determinada finalidade e, por isto, é necessário entender o alvo a ser estudado (aplicação) e os sensores que melhor se adequam a ele. Dessa maneira, como o objetivo deste trabalho é avaliar a acurácia de classificações de vegetação de manguezais, é fundamental o estudo das características deste ecossistema.

3.2 ECOSSISTEMA MANGUEZAL

Krug, Leão e Amaral (2007) definem o manguezal como um ecossistema de transição entre os ambientes terrestre e marinho, onde ocorre o encontro de águas de rios com a água do mar. Este ecossistema está distribuído em zonas tropicais e subtropicais do mundo aproximadamente entre 30° N e 30° S de latitude (GIRI et al., 2011), ocupando a faixa situada entre as marés alta e baixa, conhecida como entre marés. A figura 2, mostra a distribuição de manguezais no mundo.

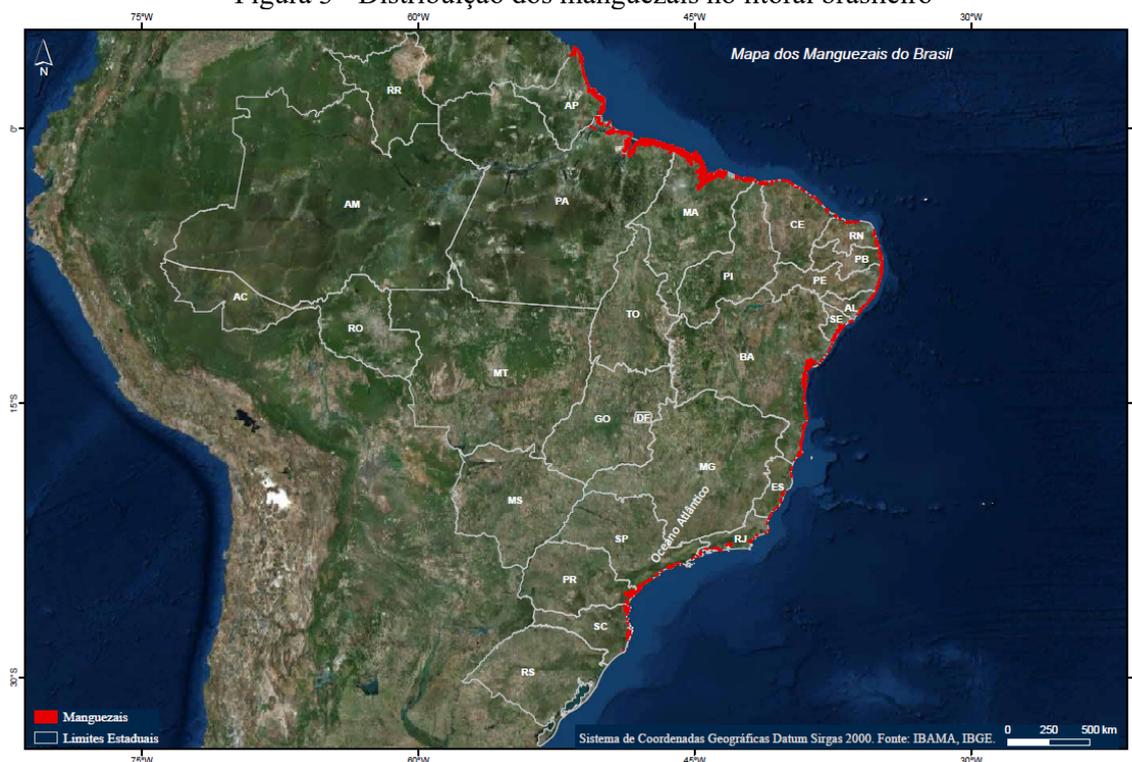
Figura 2 - Distribuição do ecossistema manguezal no mundo (em verde)



Fonte: Giri et al., 2011.

De acordo com o estudo realizado por Giri et al. (2011), o Brasil possui cerca de 7% do total do mangue existente no planeta e encontra-se distribuído de forma descontínua ao longo do litoral, entre o Amapá e Santa Catarina, como pode ser observado na figura 3.

Figura 3 - Distribuição dos manguezais no litoral brasileiro



Fonte: ICMBio, 2018.

A importância dos manguezais está relacionada a suas funções fundamentais como a manutenção da qualidade da água, fixação de sedimentos, fornecimento de produção primária e manutenção da biodiversidade (KRUG; LEÃO; AMARAL, 2007). Além disso, Rossi e Mattos (1992, p. 930) complementam que “são áreas de grande importância tanto do ponto de vista florísticos, com espécies adaptadas às condições de salinidade e carência de oxigênio, quanto faunístico, onde as espécies o utilizam como abrigo para reprodução e alimentação”. É um ecossistema que está sob influência de vários fatores como a ação das marés, as precipitações, dos aportes de água doce e salgada, dos *inputs* de sedimentos fluviais e marinhos (SCHAEFFER-NOVELLI; VALE; CITRÓN, 2015).

Em relação às características de desenvolvimento deste ecossistema, Walsh (1974) aborda 5 requisitos básicos, são eles: (1) Temperaturas tropicais, com média do mês mais frio acima de 20°C e amplitudes térmicas sazonais que não excedam 5°C; (2) solos predominantemente lodosos, constituídos de silte e argila e alto teor de matéria orgânica; (3) Áreas protegidas do estuário, livre de ações de ondas intensas e marés fortes; (4) Presença de água salgada; (5) Elevada amplitude das marés.

O manguezal pode apresentar um *continuum* de feições distintas em função do perfil da linha de costa e das frequências e amplitude das marés (SCHAEFFER-NOVELLI, 2002).

Este *continuum* de feições são: (1) O lavado, feição exposta à maior frequência de inundação, apresentando substrato lamoso ou areno-lamoso exposto, desprovido de qualquer cobertura vegetal vascularizada; (2) O mangue (bosques de mangue), vegetação característica do ecossistema, formada por plantas lenhosas; e (3) O apicum, que caracteriza pela parte mais interna do ecossistema, onde pode ser encontrada uma superfície areno-lamosa aparentemente desprovida de vida, atingida somente pelas marés de sizígia, caracterizando a sucessão natural do manguezal para outras comunidades vegetais (SCHAEFFER-NOVELLI, VALE e CITRÓN, 2015; SCHAEFFER-NOVELLI, 2018b; SCHAEFFER-NOVELLI, 2002). As figuras 4(a), (b) e (c) mostram as feições do ecossistema manguezal.

Figura 4 - Feições do manguezal. (a) Bosque de mangue e área de lavado; (b) Apicum; (c) bosque de mangue, rizóforos característicos da espécie *R. mangle*



(a)



(b)



(c)

Fonte: ICMBio, 2018.

É importante ressaltar esta diferenciação entre manguezal e mangue, pois na literatura há uma falta de concordância, principalmente em relação ao termo “*mangrove*” (mangue, em inglês) (KUENZER, et al., 2011; BLASCO et al., 1998). Schaeffer-Novelli (2018a, p. 18) explica que “o termo manguezal ou mangal é usado para descrever comunidades florestais ou

o ecossistema manguezal - espaço onde interagem populações de plantas, de animais e de micro-organismos ocupando a área do manguezal e seu ambiente físico (abiótico)”. Já o mangue, é um termo empregado para designar um grupo floristicamente diverso de árvores tropicais que compartilham características fisiológicas similares, embora pertençam a diferentes famílias botânicas sem qualquer relação taxonômica. Assim, o termo mangue se refere a uma das feições do ecossistema manguezal (SCHAEFFER-NOVELLI, 2018a; SCHAEFFER-NOVELLI; VALE; CITRÓN, 2015).

A vegetação presente nesse ecossistema enfrenta condições de elevada salinidade e temperatura, ampla variação da maré, deficiência de nutrientes, sedimento inconsolidado, além de baixas concentrações de oxigênio no sedimento (TOMLINSON, 1986; SCHAEFFER-NOVELLI, 2018b).

Os gêneros e espécies de mangue existentes no Brasil são: o gênero *Rhizophora*, conhecido popularmente como mangue-vermelho, com as espécies *R. mangle*, *R. harrisonii* e *R. racemosa*; o gênero *Laguncularia*, conhecida como mangue-branco, com a espécie *L. racemosa* e; o gênero *Avicennia*, conhecida popularmente como mangue-preto, com as espécies *A. schaueriana* e *A. germinans*. Além destas, existem as espécies que estão situados nas áreas de ecótono, como *Conocarpus erectus*, conhecido popularmente como mangue de botão (SCHAEFFER-NOVELLI, 2018b).

Na região Nordeste, são encontradas apenas 5 dessas espécies de mangue, sendo: *Rhizophora mangle* L., *Avicennia schaueriana*, *Avicennia germinans* L., *Laguncularia racemosa* L. e *Conocarpus erectus* L (CEARÁ, 2006).

Os manguezais são ecossistemas vulneráveis que vem sofrendo pressão por causa do aumento da população costeira e suas atividades como: desmatamento e aterro, lançamento de esgoto e lixo e intensa exploração dos seus recursos naturais (principalmente relacionados a extração de madeira, a fauna e o desmatamento para criação de áreas de cultivo de camarão) (KRUG; LEÃO; AMARAL, 2007). Isto pode causar perda e fragmentação da cobertura vegetal, deterioração da qualidade dos habitats aquáticos, promovendo a diminuição na oferta de recursos dos quais muitas comunidades tradicionais e setores dependem diretamente para sobreviver (ICMBio, 2018).

Todas essas características, como o valor socioeconômico, ambiental e a vulnerabilidade do ecossistema, mostra a importância de sua preservação e para isso é necessário que haja um monitoramento constante, tanto em relação a ações antrópicas quanto em relação as variações das condições ambientais existentes.

3.3 SENSORIAMENTO REMOTO APLICADO A DETECÇÃO DE MANGUEZAIS

Nas últimas décadas, o sensoriamento remoto tem sido cada vez mais usado pela comunidade científica para descrever e monitorar uma variedade de sistemas em escala local e global (DAHDOUH-GUEBAS, 2002). Aliado a isso, é notório o crescimento do uso de imagens de SR para aplicações que envolvam a identificação e monitoramento de manguezais. Trabalhos como o de Wang et al. (2019), Kuenzer et al. (2011) e Purnamasayangasukasih (2016), fazem revisões bibliográficas dos principais estudos, aplicações, técnicas e sensores utilizados para este fim nas duas últimas décadas.

Este crescimento do uso de dados de SR em aplicações relacionadas com manguezais é devido a sua capacidade de fornecer informações espaço-temporais sobre a distribuição, diferenciação das espécies, detecção de mudanças fisiológicas (SILVA et al., 2020), mudanças da cobertura do solo, observação de desastres e padrões de zonação de espécies (PURNAMASAYANGSUKASIH, 2016). Além disto, é importante destacar o aumento da utilização destes dados em decorrência do baixo custo financeiro, rapidez de obtenção da informação e o avanço na abrangência de pesquisas nas diversas áreas do conhecimento (SILVA,2012). Para Purnamasayangasukasih (2016), o uso deste tipo de dado é crucial para a obtenção de informações acuradas que facilitem planejamentos para conservação do meio ambiente e políticas públicas.

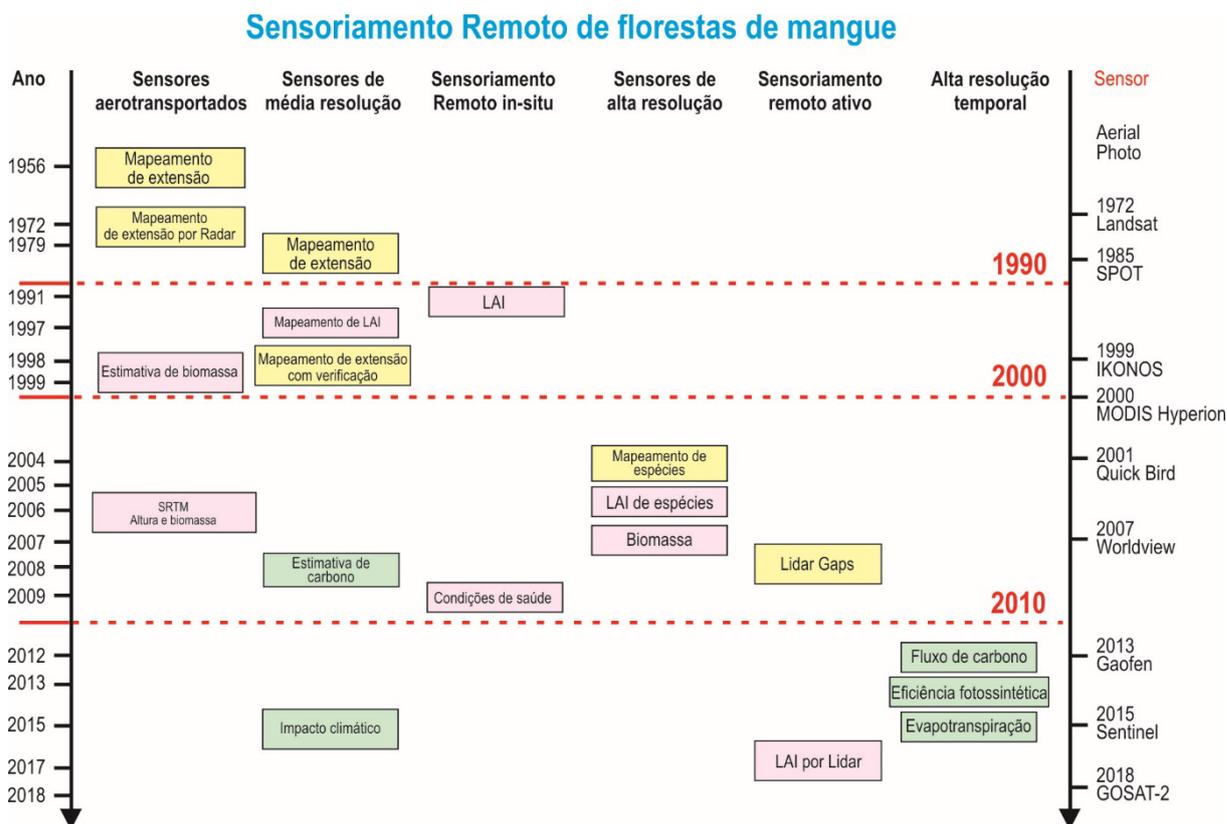
Em resumo, Kuenzer et al. (2011) cita as principais informações que podem ser fornecidas através do sensoriamento remoto em manguezais:

- Inventários de hábitat (determinação da extensão, espécie e composição, estado de saúde);
- Detecção e monitoramento de mudanças (uso da terra, cobertura da terra, sucesso de conservação e reflorestamento, silvicultura e desenvolvimento da aquicultura);
- Apoio à avaliação do ecossistema;
- Avaliação da produtividade (estimativa de biomassa);
- Estimativa da capacidade de regeneração;
- Pedidos de manejo múltiplo (pesca, atividades aquícolas, manejo de conservação, diretrizes e estratégias de manejo);
- Planejamento de pesquisas de campo;
- Avaliação da qualidade da água;
- Fornecimento imediato de informações para o gerenciamento de desastres; e

- Ajuda para obter uma melhor compreensão das relações e processos ecológicos e biológicos, funções e dinâmicas.

Wang et al. (2019), aborda uma revisão das aplicações dos estudos de manguezais utilizando dados de SR entre 1956 a 2018, dividindo o conjunto de destas aplicações em 4 períodos, como mostra a figura 5.

Figura 5 - Evolução das aplicações de sensoriamento remoto em manguezais



Fonte: Adaptado de Wang et al., 2020.

Desta figura, é possível identificar que antes de 1989 as aplicações de SR relacionadas a manguezais se resumiam ao mapeamento de sua extensão, muitas vezes realizadas sem a avaliação de acurácia. Já entre o período de 1990 até 1999, o sensoriamento remoto evoluiu para a extração de informações biofísicas da vegetação como o Índice de Área Foliar (LAI, do inglês “*Leaf area index*”), o que permitiu adquirir informações em larga escala deste importante indicador para previsão de fotossíntese, respiração, ciclo de carbono e nutrientes, transpiração e interceptação pluviométrica (WANGDOUGHTY; GOULDEN, 2015; WANG et al., 2016 *apud* WANG et al., 2020).

A partir dos anos 2000, os estudos aplicados a manguezais se voltaram para caracterizações mais detalhadas, como mostra a figura 5, mais especificamente relacionadas a

classificação das espécies, mapeamento da estrutura vertical (altura, biomassa e estoque de carbono) e recuperação de condições de saúde dos manguezais. Entre os anos de 2010 e 2018, estes estudos foram realizados de forma mais abrangente no que diz respeito a sua função ecológica, o que fez com que trabalhos pertinentes a sua influência no fluxo de carbono global, balanço energético e sua resposta a mudanças climáticas fossem desenvolvidos (WANG et al., 2019).

Dito isso, é possível perceber que o estudo de manguezais a partir de Sensoriamento Remoto é bastante consolidado, principalmente sobre o mapeamento da extensão desse ecossistema. Entretanto, isso não exige a continuidade do aprofundamento de métodos de mapeamento e classificação (mangue ou não-mangue), pois servem como base para outros estudos e aplicações (WANG et al., 2019). Partindo desse ponto, esses autores citam grandes desafios e oportunidades em relação ao mapeamento (classificação) como: 1) conduzir mapeamento global com densa resolução temporal e melhor resolução espacial; 2) considerar as influências das marés.

Esta evolução de aplicações está totalmente ligada com avanços tecnológicos que proporcionaram imagens com melhores resoluções e técnicas de processamento. Heumann (2011) faz uma análise dos avanços em dados e técnicas de sensoriamento remoto para o monitoramento em larga escala em manguezais. Mostra também os principais sensores/satélites utilizados para essa finalidade, como por exemplo os da série Landsat e o ALOS/PALSAR.

A escolha do sensor apropriado para aplicações em estudos de manguezais está relacionada a uma série de fatores. Kuenzer et al. (2011), por exemplo, cita que a escolha depende do objetivo da investigação, da escala final de mapeamento, do nível de detalhamento desejado, do período de cobertura, das características da região, do nível de recursos e treinamento de pessoal disponível para o estudo. Além disso, a necessidade do estudo irá determinar a opção por utilizar dados ópticos ou de radar e estes dois tipos de dados podem ser utilizados de maneira complementar (ASCHBACHER ET AL., 1995).

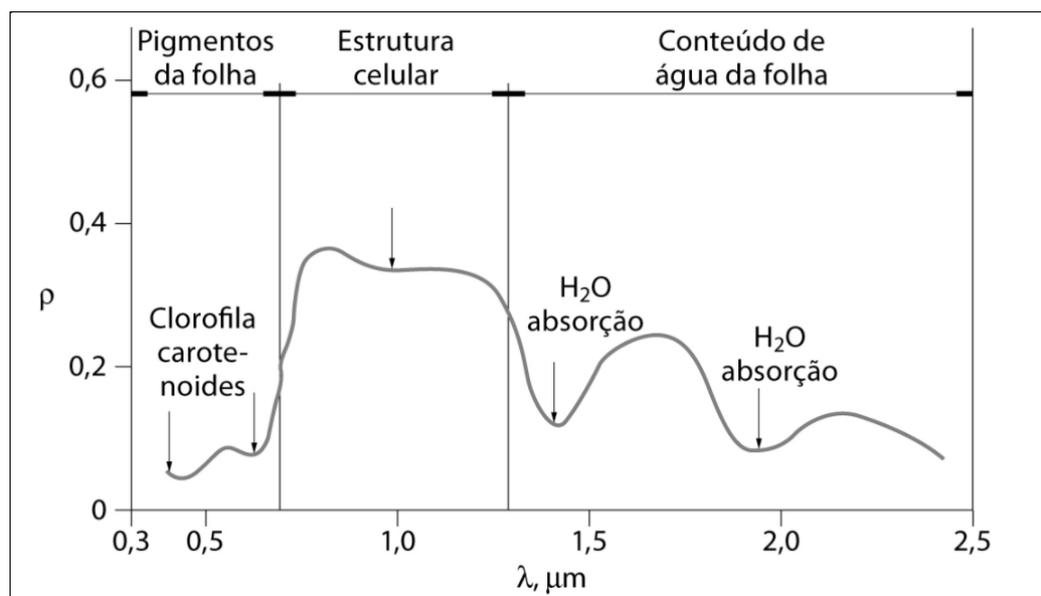
3.3.1 Características dos bosques de mangue em imagens ópticas

Para o estudo dos bosques de mangue é necessário compreender o comportamento espectral da vegetação, e seu estudo permite que seja possível a extração de informações desse alvo. O comportamento espectral da vegetação está associado a interação da energia

eletromagnética com as folhas e os dosséis, já que são os elementos visíveis nas imagens de sensores orbitais.

Vários autores como Centeno (2004), Jensen (2009), Novo (2010) e Ponzoni, Shimabukuro e Kuplich (2012), descrevem o comportamento espectral da vegetação. Na figura 6, é possível visualizar a assinatura espectral de uma folha verde sadia.

Figura 6 - Assinatura espectral característica de uma folha verde



Fonte: Ponzoni, Shimabukuro e Kuplich,2012; adaptado de Novo, 1989.

Novo (2009), por exemplo, divide a curva de reflectância da vegetação (figura 6) em 3 partes:

- a) até 0,7 μm, que se refere à região do visível. Nesta região, a reflectância da vegetação é baixa (menor que 20%), dominando a absorção por pigmentos em 0,48 μm e 0,62 μm. E em 0,52 μm há um pequeno aumento de reflectância.

Esta absorção por pigmentos acontece principalmente devido as clorofilas a e b, os mais importantes pigmentos absorvedores da luz azul e vermelha. Além disso, outros pigmentos são atuantes na absorção de energia na faixa do visível (porém em proporção menor do que as clorofilas), como os carotenos amarelos, xantofilas amarelo-claras, ficoeritrina, ficocianina e antocianina (JENSEN, 2009).

- b) entre 0,7 μm e 1,3 μm , região onde a reflectância da vegetação sadia aumenta significativamente devido a estrutura celular (mesófilo esponjoso).

Em resumo, esta região é geralmente caracterizada pela alta reflectância (40 – 60%), alta transmitância (40-60%) e relativamente baixa absorptância (5-10%) (JENSEN, 2009).

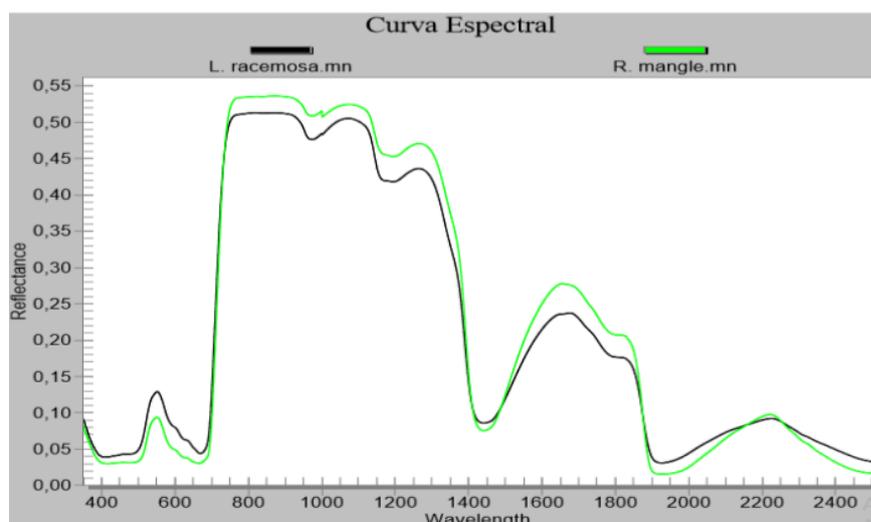
- c) entre 1,3 μm e 2,5 μm , região do infravermelho médio onde a reflectância da vegetação é dominada pelo conteúdo de água das folhas.

A relação existente nesta região é que quanto maior o teor de água nas folhas menor a reflectância. Quando a umidade diminui, os picos de absorção também diminuem e a folha passa a refletir maior quantidade de energia incidente (CENTENO, 2004).

Essas características possibilitam a compreensão de que a reflexão da radiação eletromagnética pelas folhas depende da sua composição química e de sua estrutura celular (Ponzoni, Shimabukuro e Kuplich, 2012).

A figura 7 mostra a curva espectral de folhas de duas espécies de mangue do manguezal da Baía de Vitória (ES), que se comportam como a curva típica da vegetação, com alta reflectância no infravermelho próximo e baixa reflectância no visível e no infravermelho de ondas curtas (SWIR) (SILVA et al., 2020).

Figura 7- Reflectância média de duas espécies de mangue identificadas na Baía de Vitória (ES)



Fonte: Silva et al., 2020.

O conhecimento deste comportamento espectral é importante para diferenciar o mangue de outros alvos, assim como diferenciar espécies de mangue. Silva (2012), por exemplo, faz uma comparação entre as respostas espectrais das espécies *R. mangle*, *A. schaueriana* e *L. racemosa* no estuário do rio Itapessoca (PE), utilizando espectrorradiometria. O estudo mostrou que, das três, a *R. mangle* apresenta maior reflectância na região do infravermelho próximo em relação as outras espécies e que na região do verde o comportamento dessas espécies é semelhante.

A partir da reflectância da vegetação é possível calcular os chamados índices de vegetação, que tem por finalidade realçar partes das cenas que apresentam densidades variadas de cobertura vegetal para estimar e analisar diferentes variáveis biofísicas e bioquímicas da vegetação como: clorofila, índice de área foliar, biomassa entre outros (SANO et al., 2019). Esses índices são formados a partir de operações aritméticas realizadas entre as bandas de uma imagem explorando o comportamento espectral da vegetação para realçar determinadas características (ZANOTTA; FERREIRA; ZORTEA, 2019).

Para este trabalho, serão apresentados 3 (três) índices de vegetação que serão utilizados posteriormente para processamento, sendo eles o NDVI, o NDWI e o SAVI. A escolha desses três índices está relacionada com a comum utilização deles em detecção de manguezais na literatura (KUENZER et al, 2011; WAHAB; KAMARUDIN, 2018; RHYMA et al., 2020, ZHANG et al. 2016). Mais informações sobre os principais índices de vegetação existentes podem ser encontradas em Jensen (2009) e Sano et al., (2019).

O NDVI (*Normalized Difference Vegetation Index*), desenvolvido por Rouse et al. (1974), utiliza características espectrais da vegetação nas faixas do vermelho e do infravermelho próximo. A vegetação sadia absorve radiação na região do visível, utilizando como fonte de energia para o processo de fotossíntese e reflete muita radiação na região do infravermelho próximo (RHYMA et al., 2020). O NDVI se correlaciona com certas propriedades biofísicas do dossel vegetal tais como o índice de área foliar, cobertura vegetal fracionada, condição da vegetação e biomassa (JIANG et al., 2006). Este índice é utilizado para construção de perfis sazonais e temporais das atividades da vegetação (PONZONI; SHIMABUKURO; KUPPLICH, 2012), além de realçar o contraste existente entre vegetação e outros alvos como solo e corpos hídricos. Ele pode ser calculado a partir da equação 3:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (3)$$

Onde,

ρ_{NIR} : reflectância na região do infravermelho próximo;
 ρ_{RED} : reflectância na região do vermelho.

Por ser uma razão normalizada, os valores resultantes desse cálculo estão entre -1 e 1, dependendo da reação da atividade de fotossíntese conduzida pela vegetação verde saudável (RHYMA et al., 2020). Os valores mais próximos a 1 indicam uma vegetação com maior vigor e densidade, valores próximos a 0 indicam uma superfície não vegetada e valores negativos geralmente correspondem a corpos hídricos.

Entretanto, apesar de bastante utilizado, o NDVI possui desvantagens como: (1) influência de efeitos ruidosos aditivos; (2) a sua saturação quando o LAI é muito alto, apesar de ter grande correlação; (3) sua sensibilidade a variações do substrato sob o dossel (JENSEN, 2009).

De forma a minimizar a influência do solo no resultado final do NDVI, foi proposta a inclusão de uma constante “L” gerando o índice conhecido como SAVI (Soil-Adjusted Vegetation Index) (HUETE, 1988). O SAVI é definido por (equação 4):

$$SAVI = \frac{(\rho_{NIR} - \rho_{RED}) * (1 + L)}{\rho_{NIR} + \rho_{RED} + L} \quad (4)$$

Onde,

ρ_{NIR} : reflectância na região do infravermelho próximo;

ρ_{RED} : reflectância na região do vermelho;

L: fator de ajuste para o substrato do dossel.

Esta constante “L” pode variar de 0 a 1 e os valores ótimos, segundo Huete (1988) são de: (1) L=1 para densidades baixas de vegetação; (2) L= 0,5 para densidades médias; (3) L=0,25 para densidades altas de vegetação.

O NDWI (*Normalized Difference Water Index*), também conhecido como NDMI (*Normalized Difference Moisture Index*), proposto por Gao (1996), é um índice que explora as características da vegetação baseado nas bandas do infravermelho próximo e do infravermelho médio. A reflectância da região do infravermelho médio está relacionada ao conteúdo de água existente nas plantas. Desta forma, este índice consegue acompanhar mudanças na biomassa e nos estresses de umidade da vegetação (GAO, 1996). O NDWI pode ser calculado a partir da equação 5.

$$NDWI = \frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}} \quad (5)$$

Onde,

ρ_{NIR} : reflectância na região do infravermelho próximo;

ρ_{SWIR} : reflectância na região do infravermelho médio.

Assim como os outros índices, o NDWI fornece valores que variam entre -1 e 1, em que valores próximos a 1 representam maior biomassa e conteúdo de água (ZHANG et al., 2016).

3.3.2 Características dos bosques de mangue em imagens SAR

O mapeamento da extensão e tipos de mangue teve foco na utilização de dados ópticos devido a vantagem particular desses dados de conseguirem distinguir áreas de mangue e não-mangue relativamente bem (LUCAS et al., 2009). Entretanto, existe um problema relacionado ao sensoriamento remoto óptico que é a presença de nuvens nas imagens, causando oclusão dos alvos na superfície terrestre. Isso faz que com que, muitas vezes, não seja possível a extração de informações de determinados objetos a partir destas imagens. Uma opção para resolver este problema é a utilização de imagens SAR, pois elas não são atenuadas pelos efeitos atmosféricos como ocorre no sistema óptico (PEREIRA; KAMPEL; CUNHA-LIGNON, 2011).

Os radares de abertura sintética (SAR) são sistemas ativos que transmitem sinais na faixa de micro-ondas em um ângulo de incidência oblíquo e medem o sinal do retroespalhamento na direção do sensor (MEYER, 2019). As propriedades das micro-ondas possibilitam o imageamento através de nuvens – por causa da grande transmissividade existente nessa faixa - e sua interação com feições na superfície terrestre podem proporcionar informações sobre indicadores de teor de umidade, salinidade e suas características físicas como forma, tamanho e orientação (WOODHOUSE, 2006).

Por se tratarem de sistemas ativos, os sensores SAR permitem o controle da polarização do sinal tanto na sua emissão quanto recepção, ou seja, a orientação do plano de oscilação do sinal. Desta forma, a maioria dos sensores são polarizados linearmente e podem transmitir e/ou receber de forma horizontal e/ou vertical (MEYER, 2019). A intensidade de energia que retorna para o sensor pode variar em função de parâmetros do sensor, como comprimento de onda, polarização e ângulo de incidência, além dos parâmetros do alvo como constante dielétrica, rugosidade e geometria (PEREIRA, 2011).

Um dos benefícios da utilização de SAR em estudos florestais é que, além da não atenuação da atmosfera, o retroespalhamento é sensível aos elementos estruturais florestais

(como folhas, galhos e troncos), tendo o grande potencial de estimar parâmetros biofísicos (TOWNSEND, 2002). Essa sensibilidade depende dos parâmetros do sensor, sendo um dos mais importantes a frequência do sinal de micro-ondas, pois para frequências menores a capacidade das micro-ondas em penetrar o dossel vegetal e, portanto, interagir com os componentes vegetais aumenta (LUCAS et al., 2007).

As principais bandas utilizadas no sensoriamento remoto por SAR, e suas aplicações podem ser observadas no quadro 1.

Quadro 1 - Principais bandas utilizadas no sensoriamento remoto por SAR

Banda	Frequência (GHz)	Comprimento de onda (cm)	Aplicações e características
X	8 - 12	3,8 - 2,4	SAR de alta resolução. Usado para monitoramento urbano, aplicações com gelo e neve; possui pouca penetração em vegetação.
C	4 - 8	7,5 - 3,8	Utilizado para mapeamento global, detecção de mudanças, monitoramento de áreas com pouca a moderada vegetação (Maior penetração na vegetação em relação a banda X; maior coerência;), aplicações com gelo, oceanos e navegações marinhas.
S	2- 4	15 - 7,5	Uso pequeno porem em crescimento para observação da terra utilizando SAR; Monitoramento de agricultura.
L	1 -2	30 - 15	SAR de média resolução; Aplicações em monitoramento geofísico, biomassa e mapeamento de vegetação. Tem grande penetração.
P	0.3 - 1	100 - 30	Aplicações relacionadas com biomassa, mapeamento e avaliação de vegetação.

Fonte: Adaptado de Meyer, 2019.

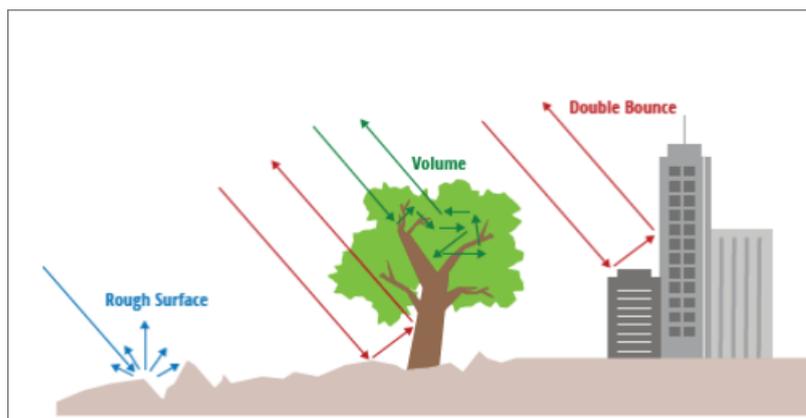
A partir deste quadro, é possível notar que quanto menor a frequência, e consequentemente maior o comprimento de onda, mais penetração na vegetação existe. Isto mostra que a utilização das bandas de menor frequência podem melhores para estudos aplicados a mapeamento de vegetação e biomassa.

Lucas et al., (2009), citam que antes do lançamento do ALOS/PALSAR em 2006, a maioria dos trabalhos de caracterização de mangues utilizando SAR eram realizadas com sensores que operavam na banda-C ($\lambda= 5,6\text{cm}$), que interage primeiramente com o dossel vegetal dos bosques de mangue e dificultava o processo de separação de mangue de outros tipos de vegetação. Como o PALSAR trabalha na região da banda-L ($\lambda=23,5\text{cm}$), e esse comprimento de onda penetra através das folhas e interage primeiramente com os componentes lenhosos da vegetação, este sensor representou um marco na observação, caracterização, mapeamento e monitoramento de mangues, principalmente por fornecer

informações sobre a estrutura tridimensional e biomassa da vegetação e a presença e extensão de inundações (LUCAS et al., 2009; LUCAS et al., 2007).

A interação das micro-ondas com as diferentes superfícies é descrita em relação aos mecanismos de espalhamento. Esses mecanismos podem ser observados simplificadaamente na figura 8.

Figura 8 - Principais mecanismos de espalhamento considerados para dados SAR

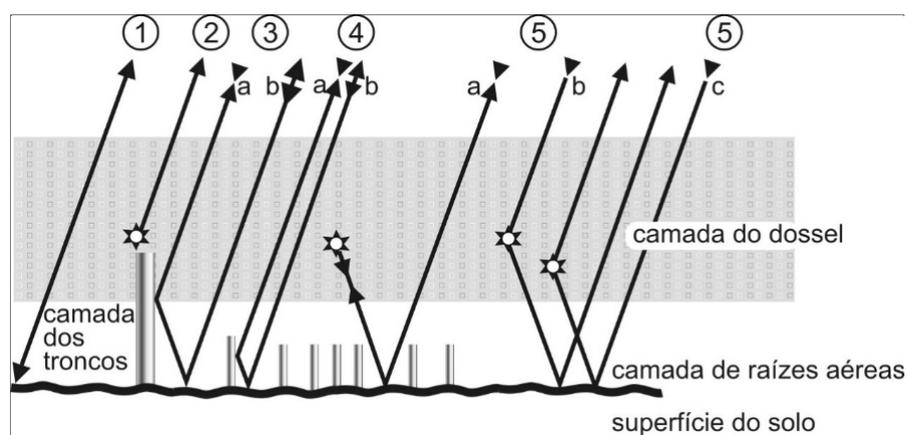


Fonte: Meyer, 2019.

A partir da figura 8 os mecanismos de espalhamento podem ser descritos em função dos alvos: o espalhamento superficial ocorre na superfície dos objetos e depende de sua rugosidade. Acontece em solos expostos, pastagens, estradas e superfícies pavimentadas; o espalhamento volumétrico acontece quando o sinal se propaga múltiplas vezes no interior dos objetos, como ocorre nos dosséis vegetais. E o espalhamento *double-bounce*, que ocorre na interação com edifícios, troncos de árvores, postes e outras estruturas verticais que desviam uma primeira reflexão inicial de volta para o sensor (MEYER, 2019).

Wang e Imhoff (1993) analisaram os mecanismos de espalhamento dos componentes do manguezal, sendo eles: (1) espalhamento de superfície (2) espalhamento volumétrico do dossel, (3) espalhamento da interação tronco-solo (*double bounce*), (4) interação entre as raízes aéreas e o solo (*double bounce*) e (5) múltiplas interações entre o dossel e o solo. Essas interações podem ser observadas na figura 9.

Figura 9 - Principais mecanismos de espalhamento relacionados aos componentes do manguezal



Fonte: Adaptado de Wang e Inhoff, 1993.

Entender os mecanismos de interação das micro-ondas com os principais componentes do manguezal é muito importante para compreensão e interpretação das imagens SAR. Simard (2019) mostra que o mecanismo de espalhamento predominante depende da estrutura do dossel vegetal. No caso dos manguezais, o espalhamento volumétrico diminui e o espalhamento *double-bounce* aumenta nas copas fechadas e abertas, respectivamente. Além disso, as marés baixas e estações secas elevam a quantidade de matéria orgânica no solo e sua rugosidade superficial, causando elevação do espalhamento superficial. O coeficiente de retroespalhamento também varia de acordo com os sistemas de raízes expostas, pois algumas espécies de vegetação suportam grandes raízes aéreas enquanto outras têm pneumatóforos (LUCAS et al., 2007). Já quando a superfície dos manguezais está alagada, o retroespalhamento *double-bounce* aumenta, devido a interação dos troncos e com os solos alagados (RICHARDS et al., 1987; WANG; IMHOFF, 1993).

Embora essas iterações sejam bem conhecidas, segundo Lucas et al., 2007, o mapeamento e caracterização de mangues usando a banda L é complicado por:

- 1) similaridades na resposta da banda-L de mangues e áreas florestais adjacentes;
- 2) mangues com extenso sistema de raízes aéreas têm um retroespalhamento menor na banda-L (particularmente na polarização HH), o que pode causar confusão com áreas não vegetadas;
- 3) o retroespalhamento da banda-L é realçado quando mangues estão totalmente inundados;

Por isto, pode-se adicionar outros tipos de informações para melhor caracterização dos mangues, como por exemplo imagens ópticas (TOWNSEND, 2002; LUCAS et al., 2007).

Desta forma, o uso em conjunto desses dois tipos de dados pode fornecer melhor performance em classificações desse ecossistema (ABDEL-HAMID et al., 2017; JHONNERIE et al., 2015, KUENZER et al., 2011).

3.4 CLASSIFICAÇÃO DIGITAL DE IMAGENS

A detecção de objetos em imagens de Sensoriamento Remoto pode ser realizada de forma visual, por meio da fotointerpretação - em que o analista usa de elementos como cor, textura, forma, tamanho e padrões, para identificar objetos - e também por técnicas de processamento digital de imagens (PDI) que permitem uma automação na aquisição de informações. Nesse sentido, a função primordial do PDI é facilitar a identificação e a extração de informações contidas nas imagens para posterior interpretação (CRÓSTA, 1992).

Um dos processos que permitem a distinção e o reconhecimento dos diferentes materiais existentes na superfície é a classificação automática. Ela se baseia nos comportamentos específicos de cada material ao longo do espectro eletromagnético, em que a intensidade da energia eletromagnética refletida pelo objeto é registrada pelo sensor e é associada a um pixel na imagem.

Segundo Crósta (1992), o pixel representa o menor elemento de uma imagem, com localização “x” e “y” definida em um sistema de coordenadas representando uma área na superfície terrestre. Cada pixel, possui uma dimensão “z” denominado nível de cinza ou número digital (ND) que retrata a intensidade da energia eletromagnética medida pelo sensor. Portanto, a classificação automática tem a finalidade de atribuir “rótulos” aos pixels que os associem a um objeto real, por meio de algoritmos computacionais, levando em consideração seus números digitais.

Os classificadores podem ser divididos em classificações **pixel-a-pixel** ou **por regiões**, onde os primeiros levam em consideração as informações espectrais dos pixels para rotular regiões com características semelhantes por meio de regras de probabilidade. Já os por região, realizam um processo de agrupamento dos pixels preliminarmente à classificação. Outra categorização são a de classificadores **supervisionados**, em que o usuário contribui com seu conhecimento da área para definir as classes, ou **não supervisionados**, em que o analista não participa da seleção dos grupos (classes) e é o computador que gera automaticamente a separação de classes (CENTENO, 2004).

Além disso, os algoritmos de classificação podem ser definidos como **paramétricos** ou como **não paramétricos**, sendo os paramétricos caracterizados por modelarem as

fronteiras de decisão entre as classes de treinamento com um número fixo de parâmetros independentemente do número de amostras disponíveis (RUSSEL; NORVIG, 2009), fazendo uma suposição inicial sobre a forma da distribuição de probabilidade das classes (ZANOTTA; FERREIRA; ZORTEA, 2019). O desempenho e exatidão dos classificadores paramétricos está ligado à distribuição normal dos dados, ocasionando problemas quando se utiliza imagens com comportamento mais heterogêneo (ANDRADE; FRANCISCO; ALMEIDA, 2014). Em contrapartida, os classificadores não paramétricos não demandam que os dados sigam alguma distribuição em particular, ou seja, eles focam a estrutura local dos dados sem assumir *a priori* uma forma específica a função que será ajustada (ZANOTTA; FERREIRA; ZORTEA, 2019).

3.4.1 Máxima Verossimilhança (MaxVer)

Um dos classificadores supervisionados paramétricos mais comuns utilizados com imagens de sensoriamento remoto é o Máxima Verossimilhança (MaxVer) (RICHARDS; JIA, 2006). Esse classificador considera a ponderação das distâncias entre as médias dos valores dos pixels das classes utilizando parâmetros estatísticos. Ele assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe específica (INPE, 2008). Parte do princípio de que cada pixel é classificado à classe que tem a mais alta probabilidade de pertencer, ou seja, sua máxima verossimilhança.

Matematicamente, Richards e Jia (2006) descrevem que, sendo x um vetor de níveis de cinza para um pixel no espaço multiespectral, a classificação por MaxVer, é feita de acordo com:

$$x \in \omega_i, \text{ se } p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j) \text{ para todo } j \neq i \quad (6)$$

onde,

ω_i = classe i ;

$p(x|\omega_i)$ = probabilidade de x pertencer a classe ω_i ;

$p(\omega_i)$ = probabilidade da classe ω_i ocorrer na imagem.

Como esse classificador assume que todas as classes têm a distribuição de probabilidade normal multivariada as probabilidades ($p(x|\omega_i)$ e $p(\omega_i)$) são calculadas a partir dos dados de treinamento fornecidos pelo analista. Um aprofundamento da matemática

envolvida nesse classificador pode ser encontrado em Richards e Jia (2006), Centeno (2004) e Meneses e Almeida (2012).

Segundo Crósta (1992), para a classificação utilizando este classificador ser precisa, é necessário que haja um número razoavelmente elevado de pixels para cada conjunto de dados de treinamento (preferencialmente acima de cem) para que não haja o risco de o tamanho da amostra não seja suficiente para a classe se aproximar de uma distribuição normal. Além disto, o autor recomenda que, por ser um classificador com base na probabilidade, tenha-se números de pixels por classe de amostragem semelhantes e que sejam tomadas mais do que uma área de amostragem por classe.

Percebe-se, portanto, que o MaxVer é um classificador dependente das amostras coletadas e da quantidade de amostras, exigindo do usuário bastante atenção e conhecimento da imagem a ser classificada. Caso o usuário não consiga definir áreas de treinamento bastante representativas, pode acontecer de a imagem classificada conter imprecisões (CRÓSTA,1992).

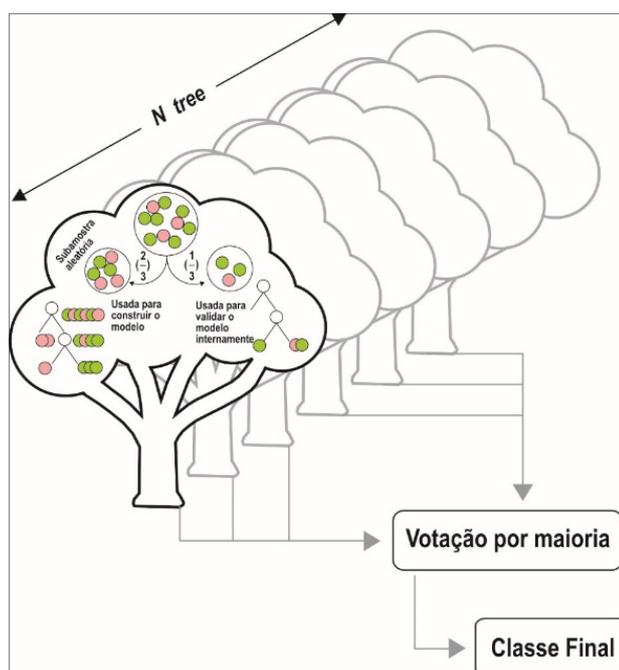
3.4.2 *Random Forest (RF)*

O *Random Forest* é um classificador não paramétrico, desenvolvido por Breiman (2001), que tem uma abordagem de aprendizagem em conjunto. Sheykhmousa et al. (2020, p. 5) afirma que “aprendizagem em conjunto é um esquema de aprendizagem de máquina (*machine learning*) para aumentar a precisão através da integração de vários modelos para resolver o mesmo problema”. Desta forma, a integração de vários classificadores em conjunto diminui a variância e pode produzir resultados mais confiáveis (SHEYKHOUSA et al., 2020).

O RF parte desse princípio e sua ideia básica consiste em combinar várias classificações provenientes de várias árvores de decisões, treinadas individualmente em distintos subconjuntos de dados. Esse classificador seleciona aleatoriamente subconjuntos das amostras de treinamento (*bootstrap dataset*) e seus atributos, produzindo várias árvores de decisão e, a partir disto, são introduzidos os dados de entrada simultaneamente em cada árvore (ZANOTTA; FERREIRA; ZORTEA, 2019).

Das amostras de classificação, dois terços dela são usadas para treinar as árvores, enquanto o um terço restante é usado para validação cruzada interna para estimação do desempenho do modelo, como mostra a figura 10.

Figura 10 - Modelo do Random Forest



Fonte: Adaptado de Sheykhmousa et al., 2020.

Da figura 10, pode-se verificar que a classe final é definida a partir da classificação proveniente de cada árvore num processo conhecido como votação por maioria. A classe final a ser rotulada será aquela que tiver mais votos.

Para a utilização do RF, é necessário estabelecer 2 parâmetros: o número de árvores (Ntree) e o número de variáveis a serem selecionadas e testadas nas árvores (Mtry) (BELGIU; DRĂGUȚ, 2016). Estes autores ainda mostram que estudos recomendam o uso do valor de 500 para Ntree, pois a acurácia da classificação não melhora acima deste valor. Para o Mtry, que depende dos dados utilizados, é recomendado configurar para a raiz quadrada do número de variáveis de entrada.

As principais vantagens relacionadas a utilização do RF são a precisão, a eficiência na implementação de grandes conjuntos de dados (BREIMAN, 2001) e pode ser de grande interesse na classificação de dados provenientes de diversas fontes (KULKARNI; LOWE; 2016). Além desses autores, Sheykhmousa et al. (2020) resumem outras vantagens do RF como:

- 1) manusear milhares de variáveis de entrada sem eliminação;
- 2) reduzir a variância sem aumentar o viés das predições;
- 3) computar as proximidades entre pares de amostras que podem ser usados na localização de *outliers* (valores atípicos);
- 4) ser robusto a *outliers* e ruídos; e

5) ser computacionalmente mais leve em comparação com outros métodos de conjunto de árvores.

Outra característica importante do RF é que as amostras utilizadas para validar o modelo são usadas para avaliar a medida de importância das variáveis (do inglês *Variable Importance Measures* – VIMs) (BOULESTEIX et al., 2012). O VIM permite ao modelo avaliar e classificar as variáveis em termos de significância relativa, ou seja, quais variáveis foram mais significativas para a classificação.

3.5 ANÁLISE DA ACURÁCIA DE CLASSIFICAÇÕES

A avaliação de acurácia de uma classificação é um passo muito importante para analisar dados de SR (BANKO, 1998). Ela é definida como a proximidade dos resultados das observações, cálculos ou estimativas aos valores verdadeiros ou aos valores aceitos como verdadeiros (USGS, 1990). Ou seja, diferentemente da precisão - que expressa o grau de dispersão da distribuição das observações - a acurácia é um conceito que está relacionado ao grau de proximidade de uma grandeza estatística com o valor considerado verdadeiro para o qual ela foi estimada (MONICO et al., 2009).

Depois que uma classificação é realizada, é necessário que uma avaliação dos resultados seja feita. Esta avaliação tem uma importância tão grande que, segundo Lillesand, Kiefer e Chipman (2015, p. 576), está associada a frase: “uma classificação não está completa até que sua exatidão seja avaliada”. Isto está relacionado ao fato de todas aplicações requerem uma avaliação de exatidão quantitativa para reforçar confiança nas informações geradas em qualquer relatório ou inferências que sejam feitas a partir deles (OLOFSSON et al., 2014).

Reforçando essa necessidade, Congalton (2001) cita algumas das razões pelas quais a avaliação de acurácia é tão importante:

1. A necessidade de saber o quão bem você está realizando (a classificação) e de aprender com seus erros;
2. A capacidade de comparar quantitativamente os métodos de classificação; e
3. A capacidade de usar as informações resultantes de sua análise de dados espaciais em algum processo de tomada de decisão.

3.5.1 Matriz de erro

A forma mais comum de expressar a acurácia de uma classificação é preparando a matriz de erro (também conhecida como matriz de confusão ou matriz de contingência) (LILLESAND, KIEFER e CHIPMAN, 2015; CONGALTON, 1991; CONGALTON, 2001). As matrizes de erro comparam, categoria por categoria, a relação entre os dados de referência conhecidos (verdade terrestre) e os resultados correspondentes de uma classificação automatizada (LILLESAND; KIEFER; CHIPMAN, 2015). Estes dados de referência podem ser coletados de várias fontes incluindo fotointerpretação, observações medições de campo (CONGALTON, 2001).

Esta matriz é representada por uma matriz quadrada que expressa o número de unidades de amostra (pixels, grupos de pixels ou polígonos) atribuídos a uma categoria específica em relação a categoria geral. As colunas representam os dados de referência enquanto as linhas indicam a classificação gerada a partir dos dados de Sensoriamento Remoto. A diagonal principal da matriz lista as unidades de amostra corretamente classificadas (CONGALTON, 1991; CONGALTON, 2001).

A representação da matriz de erro é mostrada na tabela 1, além disso as métricas ou medidas descritivas baseadas em Congalton e Green (2019) que podem ser obtidas a partir da matriz de erros podem ser vistas nas equações 7, 8 e 9.

Tabela 1 - Exemplo esquemático de uma matriz de erro

		Referência				
		Classe 1	Classe 2	Classe 3	Classe k	Total (n_{i+})
Classificação	Classe 1	n_{11}	n_{12}	n_{13}	n_{1k}	n_{1+}
	Classe 2	n_{21}	n_{22}	n_{23}	n_{2k}	n_{2+}
	Classe 3	n_{31}	n_{32}	n_{33}	n_{3k}	n_{3+}
	Classe k	n_{k1}	n_{k2}	n_{k3}	n_{k4}	n_{k+}
	Total(n_{+j})	n_{+1}	n_{+2}	n_{+3}	n_{+k}	n

Fonte: Adaptado de Congalton e Green, 2019 e Orloffson et al., 2014.

Congalton e Green (2019) explicam que assumindo que n amostras são distribuídas em k^2 células, cada amostra é atribuída a uma das k classes no mapa (geralmente as linhas) e, independentemente, para uma das mesmas k classes no conjunto de dados de referência (geralmente as colunas). O termo n_{ij} denota o número de amostras classificadas na classe i ($i=1,2, \dots, k$) no mapa e na classe j ($j=1,2, \dots, k$) nos dados de referência. Os autores utilizam o

termo n_{+i} para indicar o somatório das amostras na coluna i e o termo n_{i+} para o somatório do número de amostra na linha i .

Sabendo que na diagonal principal da matriz estão as unidades de amostra corretamente classificadas, a acurácia global (OA, do inglês *Overall Accuracy*) entre os dados classificados e os dados de referência podem ser computados pela equação 7.

$$OA = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (7)$$

Em outras palavras, acurácia global é obtida através da divisão do número total de unidades de amostra corretamente classificadas (soma dos valores da diagonal principal) pelo número total de unidades de amostra de referência (n).

Além do OA, outras métricas com a finalidade de representar a acurácia de uma classe ou categoria individualmente e podem ser calculadas de maneira semelhante, como a acurácia do produtor e acurácia do usuário.

A acurácia do produtor (PA, do inglês *Producer's Accuracy*) mede o quão bem uma determinada área (ou classe) foi classificada (BANKO, 1998). Pode ser calculada através da divisão do número de pixels (ou unidades de amostras) corretamente classificados em cada categoria (na diagonal principal n_{jj}) pelo número de pixels do conjunto de teste usado para essa categoria (o total da coluna n_{+j}). Matematicamente, a acurácia do produtor para uma classe j pode ser calculada a partir da equação 8.

$$PA_j = \frac{n_{jj}}{n_{+j}} \quad (8)$$

Já a acurácia do usuário (UA, do inglês *User's Accuracy*), é uma medida de confiabilidade do mapa (BANKO, 1998), ou seja, a probabilidade de que um pixel classificado em uma determinada categoria represente essa categoria na realidade (LILLESAND; KIEFER; CHIPMAN, 2015).

$$UA_i = \frac{n_{ii}}{n_{i+}} \quad (9)$$

Quando as unidades de amostra são de tamanho diferentes, uma abordagem baseada na contagem para gerar a matriz de erros, já não é mais apropriada. No lugar dela, uma matriz de erros baseada na área (ou proporção de área) pode ser utilizada (CONGALTON; GREEN, 2019). Olofsson et al. (2014), indicam a utilização da matriz de erro baseada em proporção de área como uma boa prática para avaliação de acurácia, permitindo estimar a acurácia do usuário e do produtor de forma imparcial e a estimativa de área das classes de acordo com os dados de referência e do erro padrão das estimativas das áreas. A tabela 2, mostra a adaptação da matriz de erro baseada em contagem de unidades de amostra para proporção de área.

Tabela 2 - Exemplo matemático de uma matriz de erro baseada em proporção de área

		Referência				
		Classe 1	Classe 2	Classe 3	Classe k	Total (n_{i+})
Classificação	Classe 1	p_{11}	p_{12}	p_{13}	p_{1k}	p_{1+}
	Classe 2	p_{21}	p_{22}	p_{23}	p_{2k}	p_{2+}
	Classe 3	p_{31}	p_{32}	p_{33}	p_{3k}	p_{3+}
	Classe k	p_{k1}	p_{k2}	p_{k3}	p_{4k}	p_{k+}
	Total(n_{+j})	p_{+1}	p_{+2}	p_{+3}	p_{+k}	1

Fonte: Adaptado de Olofsson et al. (2014).

Desta forma, baseado em Olofsson et al. (2014), a quantidade absoluta de amostras n_{ij} (ou pixels nas amostras) pode ser convertida em proporção de área estimada \hat{p}_{ij} a partir da equação 10,

$$\hat{p}_{ij} = W_i \frac{n_{ij}}{n_{i+}} \quad (10)$$

Em que,

\hat{p}_{ij} = proporção de área estimada para a classe da imagem classificada i e a classe de referência j ;

W_i = proporção de área da classe da imagem classificada i , calculada pela divisão da área ocupada pela classe i sobre o total de área da imagem classificada;

n_{ij} = número de pixels para a classe da imagem classificada i e a classe de referência j ;

n_{i+} = número total de pixels para a classe i .

A partir disto, as principais métricas como acurácia global, acurácia do usuário e do produtor baseada em proporção de área podem ser calculadas de forma análoga as equações 11, 12 e 13.

A acurácia global, portanto, é descrita pela equação 11,

$$\widehat{OA} = \sum_{i=1}^k \widehat{p}_{ii} \quad (11)$$

\widehat{OA} = estimativa de acurácia global para cada classe;

\widehat{p}_{ii} = proporção estimada para a classe ponderada pela proporção de área estimada.

Já a acurácia de produtor, portanto, pode ser descrita pela equação abaixo,

$$\widehat{PA}_j = \frac{\widehat{p}_{jj}}{\widehat{p}_{+j}} \quad (12)$$

Em que,

\widehat{PA}_j = estimativa da acurácia do produtor para a classe j ;

\widehat{p}_{jj} = proporção estimada para a classe j ponderada pela proporção de área estimada (Wi);

\widehat{p}_{+j} = total da proporção estimada para a classe j ponderada pela proporção de área estimada;

Similarmente, a acurácia do usuário pode ser descrita em termos de proporção de área através da equação,

$$\widehat{UA}_i = \frac{\widehat{p}_{ii}}{\widehat{p}_{i+}} \quad (13)$$

Onde,

\widehat{UA}_i = estimativa da acurácia do usuário para a classe i ;

\widehat{p}_{ii} = proporção estimada para a classe i ponderada pela proporção de área estimada (Wi);

\widehat{p}_{i+} = total da proporção estimada para a classe i ponderada pela proporção de área estimada;

Outras métricas, portanto, podem ser estimadas como o intervalo de confiança para acurácia global (IC) e a variância estimada para a acurácia global ($\widehat{V}(\widehat{AO})$). A variância estimada para a acurácia global pode ser calculada segundo a equação 14.

$$\widehat{V}(\widehat{AO}) = \sum_{i=1}^k W_i^2 \widehat{UA}_i (1 - \widehat{UA}_i) / (n_{i+} - 1) \quad (14)$$

Onde,

$\widehat{V}(\widehat{AO})$ = variância estimada para a acurácia global;

W_i = proporção de área da classe da imagem classificada i ;

\widehat{UA}_i = estimativa da acurácia do usuário para classe i ;

n_{i+} = número total de pixels para a classe i .

Por fim, o intervalo de confiança para a acurácia global pode ser calculado por,

$$IC = \widehat{AO} \pm t_{tab} * \sqrt{\widehat{V}(\widehat{AO})} \quad (14)$$

Em que,

IC = intervalo de confiança para a acurácia global;

\widehat{AO} = estimativa da acurácia global;

t_{tab} = valor de teste t para 95% de probabilidade encontrado na tabela *t student* ($t_{tab} = 1,96$);

$\widehat{V}(\widehat{AO})$ = variância estimada para a acurácia global.

3.5.2 Índice Kappa

Outra métrica que é utilizada para avaliação de acurácia de mapas de cobertura da terra é o índice Kappa. A análise Kappa é uma técnica multivariada discreta utilizada na avaliação da precisão para determinar estatisticamente se uma matriz de erros é significativamente diferente de outra (BISHOP et al., 1975). Ela utiliza os elementos da matriz de confusão retratando o grau de concordância dos dados, gerando, assim um aspecto de confiabilidade e precisão dos dados classificados (PERROCA; GAIDZINSKI, 2003). Em outras palavras, a estatística Kappa é a medida da diferença entre a concordância real entre os dados de referência e um classificador automático e a concordância casual entre os dados de referência e um classificador aleatório (LILLESAND; KIEFER; CHIPMAN, 2015).

O resultado de realizar uma análise Kappa é uma estatística KHAT (\hat{K} uma estimativa da Kappa), que também pode ser usada como outra medida de concordância ou acurácia (COHEN, 1960). A equação 15 mostra o cálculo de KHAT baseado nas variáveis da matriz de confusão da tabela 1, segundo Congalton e Green (2019).

$$\hat{K} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (15)$$

Os valores de Kappa variam no intervalo de 0 a 1, sendo os valores próximos a 1 significando uma melhor qualidade dos dados classificados. Isto pode ser visto na tabela 3 através do agrupamento qualitativo proposto por Fonseca (2000).

Tabela 3 - Agrupamento qualitativo de valores de kappa

Índice Kappa	Desempenho
<0	Péssimo
$0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

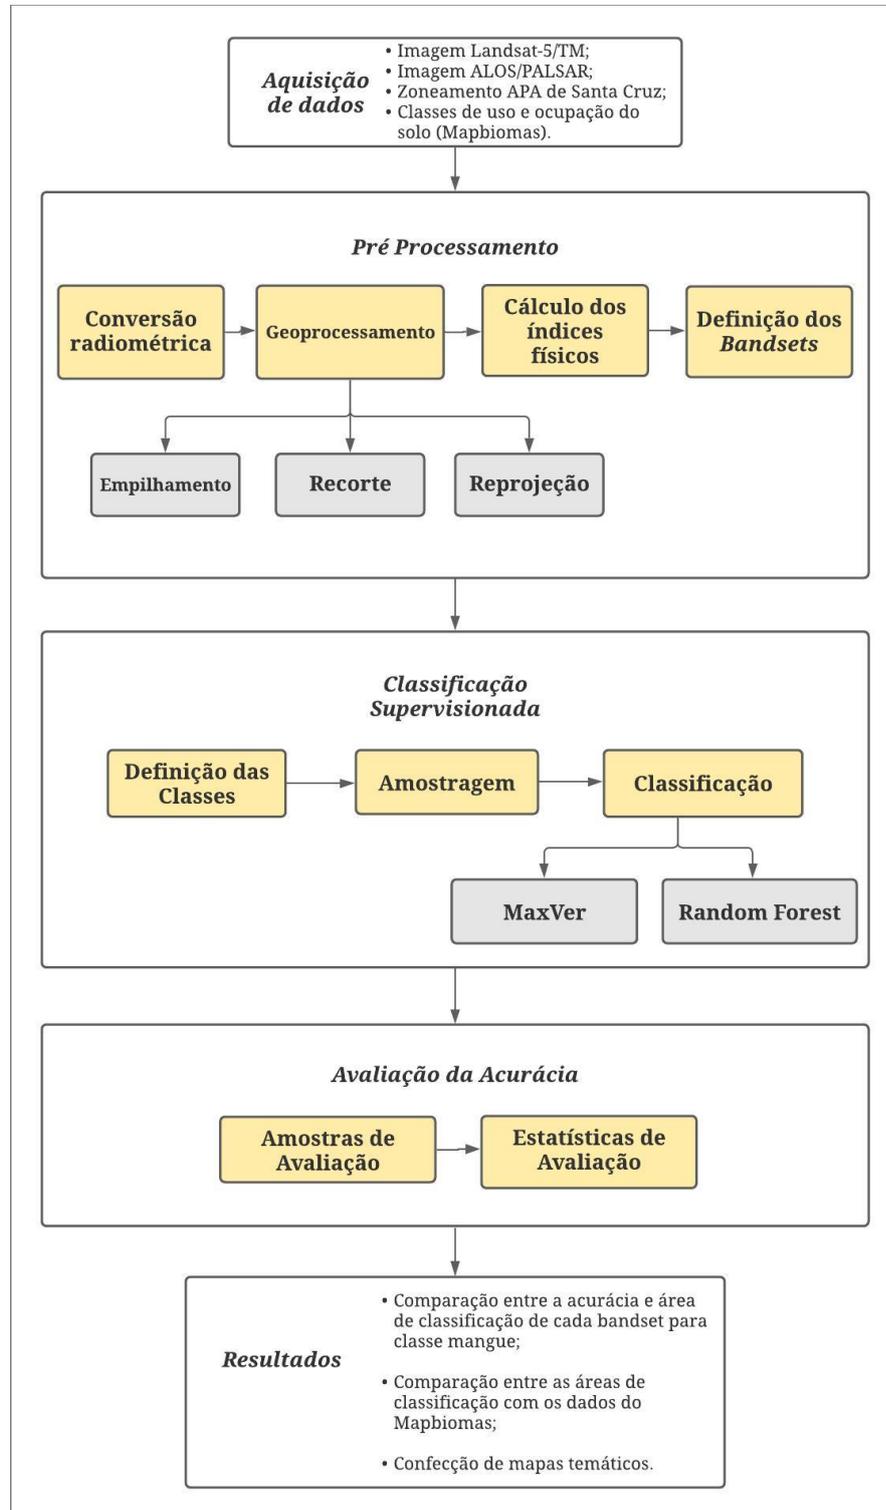
Fonte: Fonseca, 2000.

Apesar do coeficiente Kappa ainda ser bastante utilizado para avaliação de acurácia em dados de Sensoriamento Remoto, existem preocupações que faz com que ele não seja recomendado para medida geral de acurácia de um mapa (STRAHLER et al., 2006). Foody (2002), em sua revisão de literatura aborda a superestimação da concordância casual no cálculo de kappa o que subestima a acurácia da classificação, além de não ser uma medida baseada em probabilidade (STEHMAN; CZAPLEWSKI, 1998). Olofsson et al. (2014) e Pontius e Millones (2011) também citam alguns problemas relacionados ao kappa e desaconselham seu uso.

4 METODOLOGIA

O processo metodológico foi estabelecido conforme fluxograma a seguir (figura 11):

Figura 11 - Fluxograma da metodologia abordada



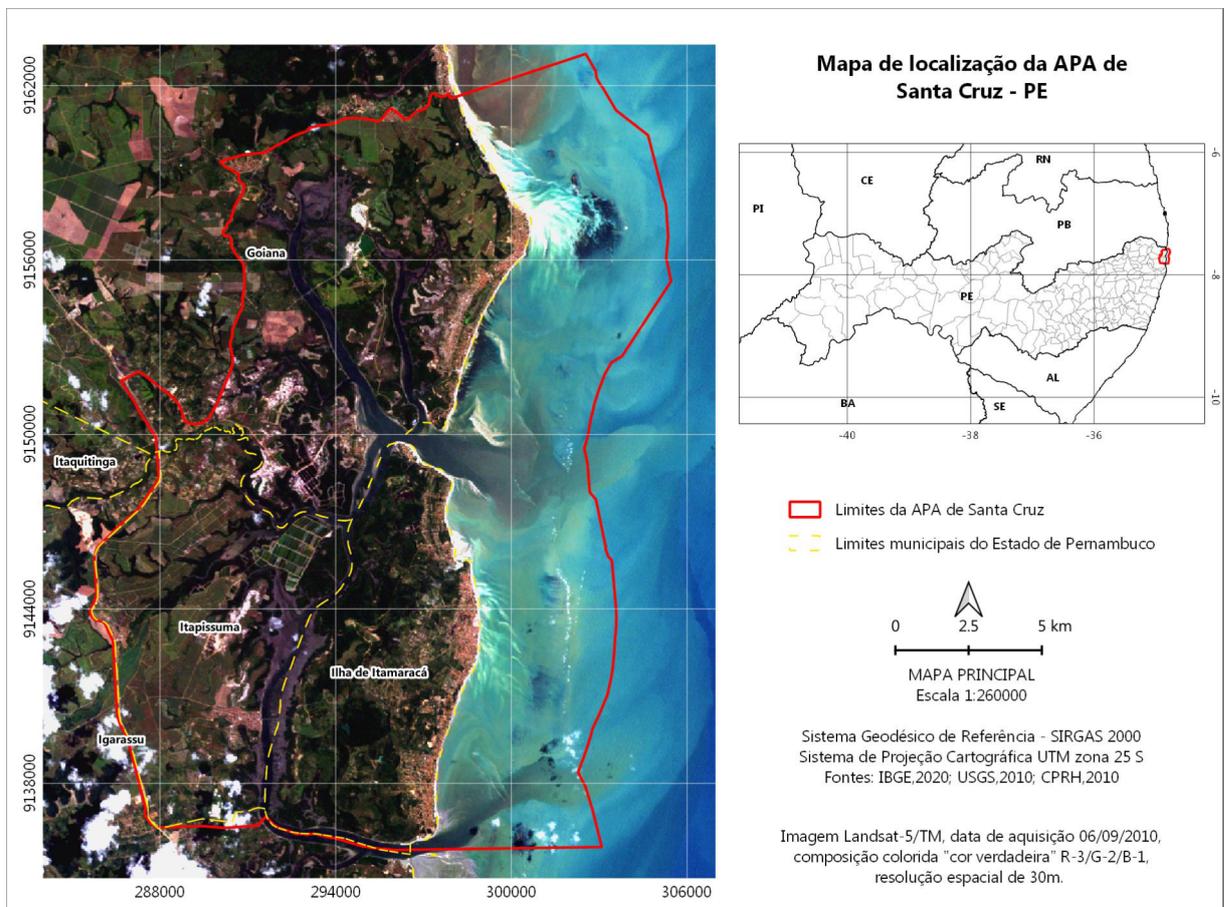
Fonte: O autor, 2021.

A partir deste fluxograma é possível verificar todas as etapas metodológicas, partindo da aquisição de dados e passando pelas etapas de pré-processamento, classificação supervisionada e avaliação da acurácia das classificações, até chegar à elaboração de mapas temáticos e comparação dos resultados obtidos.

4.1 ÁREA DE ESTUDO

Para a aplicação da classificação supervisionada utilizando os classificadores citados, a área de estudo escolhida foram os bosques de mangue existentes na Área de Proteção Ambiental (APA) de Santa Cruz (PE). Ela é uma Unidade de Conservação (UC) de uso sustentável (figura 12), criada a partir do Decreto nº 32.488 de 17 de outubro de 2008, abrangendo os Municípios de Itamaracá, Itapissuma e parte de Goiana, contendo uma área total de 38.692ha, sendo 24.943ha correspondentes à área continental e 13.749ha correspondentes à área marítima.

Figura 12 - Mapa de localização da área de estudo



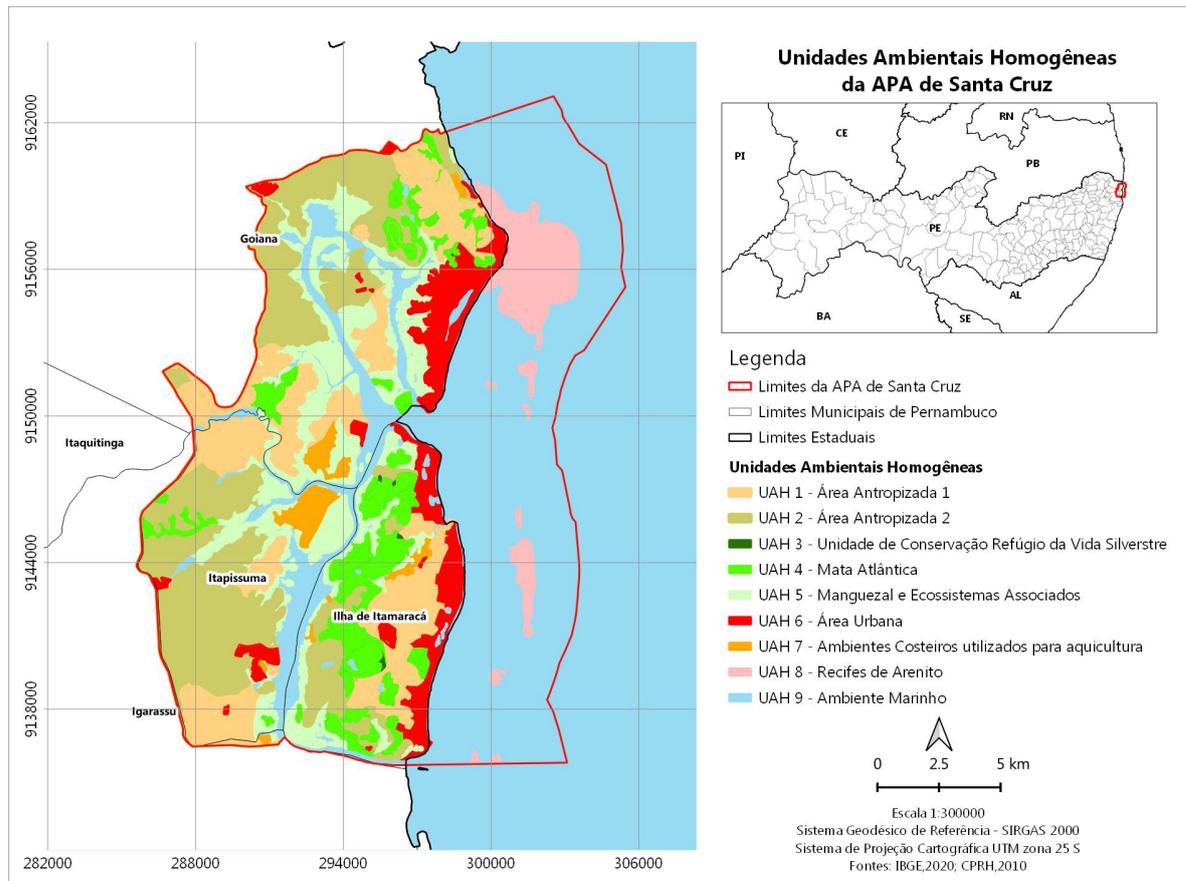
Fonte: O autor, 2021.

A criação da APA de Santa Cruz está intrinsecamente ligada aos impactos sobre o meio ambiente causados pela ação humana, e teve o objetivo de proteger a diversidade biológica e os recursos hídricos, além de disciplinar o processo de ocupação do solo, preservar paisagens e assegurar a sustentabilidade do uso dos recursos naturais dessa região (COUTINHO; SULAIMAN; CARBONE, 2018).

Sua relevância ecológica está relacionada à presença de várias Unidades de Conservação (UC's) como seis Refúgios de Vida Silvestre (RVS's): Mata de Amparo, Mata do Engenho São João, Mata Engenho Macaxeira, Mata de Jaguaribe, Mata Lanço dos Cações e Mata de Santa Cruz (LEI ESTADUAL nº 13.539, 12/09/2008). Estas áreas apresentam vegetação de Mata Atlântica e vêm sofrendo com a pressão das atividades como: desmatamentos, queimadas, ocupações irregulares, despejos de lixo e caça de aves, pequenos mamíferos e répteis (COUTINHO, SULAIMAN & CARBONE, 2018). Além disso, a APA possui três áreas estuarinas definidas como áreas de proteção: Estuário do rio Itapessoca, Estuário Jaguaribe e Complexo Estuarino Canal de Santa Cruz (LEI ESTADUAL nº 9.931, 11/12/ 1986), sendo o Complexo Estuarino do Canal de Santa Cruz é um dos ecossistemas mais importantes do litoral do Estado de Pernambuco, em virtude de sua grande biodiversidade e produtividade primária e secundária, representando uma unidade ecológica de grande significado ambiental e socioeconômico (FADURPE/CPRH, 2010).

O zoneamento do território da APA de Santa Cruz delimita as áreas conforme o padrão paisagístico do terreno, agrupando espaços que possuam características similares identificáveis. Cada delimitação é denominada de Unidades Ambientais Homogêneas (UAH) e foram estabelecidas com base nas diferenciações de um ou mais componentes de relevo, cobertura vegetal, clima, pedologia, arranjo estrutural e tipo de litologia. A figura 13 mostra a divisão da APA no que diz respeito as Unidades Ambientais Homogêneas.

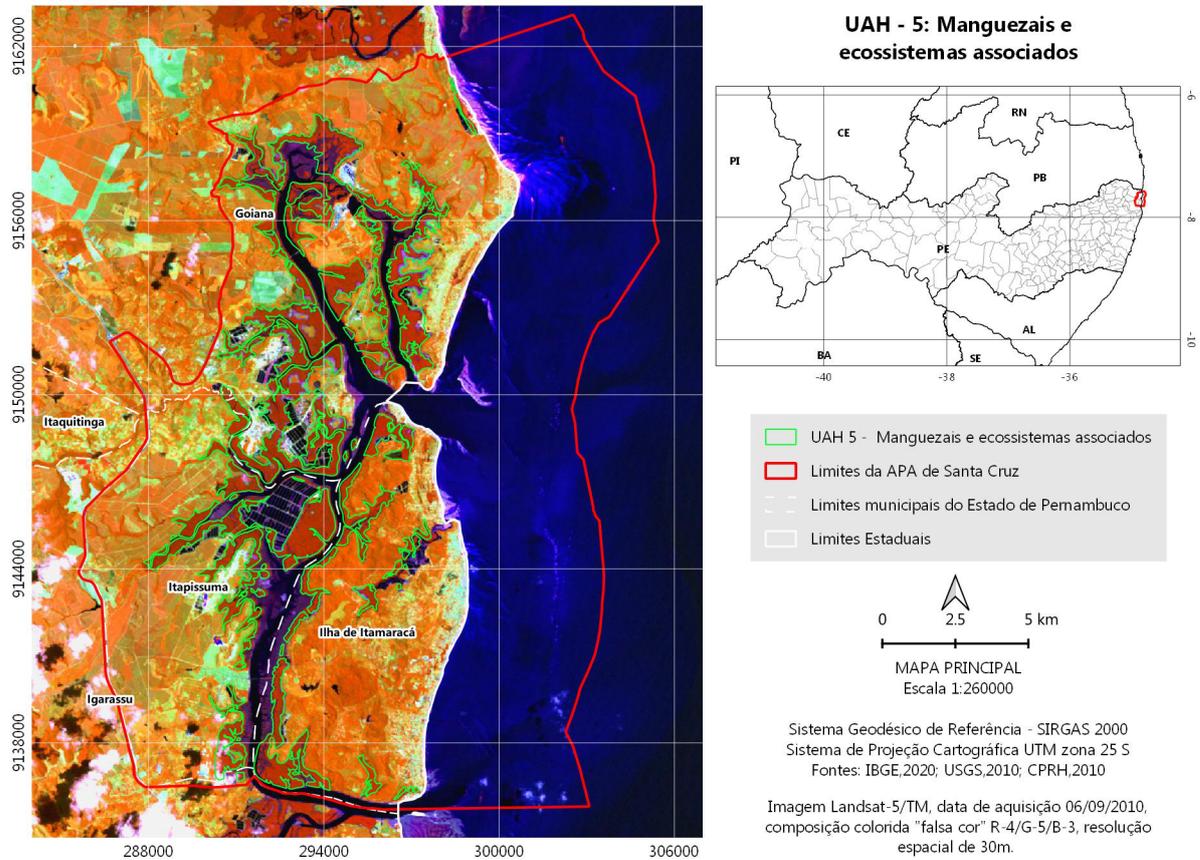
Figura 13 - APA de Santa Cruz



Fonte: FADURPE/CPRH, 2010b.

Dentro desses critérios, a unidade ambiental que engloba o Manguezal e Ecossistemas associados corresponde a UAH 05 que é equivalente a 10,55% da APA com uma área de 4.082,02ha (FADURPE/CPRH, 2010a). A figura 14 mostra a localização da UAH 5 individualmente na APA de Santa Cruz.

Figura 14 - UAH 5 (em verde) sobre composição colorida falsa cor RGB453, realçando a vegetação existente nos manguezais



Fonte: O autor, 2021

De acordo com FADURPE/CPRH (2010b), esta unidade tem grande importância ecológica, devido a várias espécies de peixes, crustáceos e moluscos que utilizam esses ambientes como área de proteção, alimentação e reprodução. Além disso, a UAH 5 tem uma importância econômica para as populações locais por fornecer alimento, combustível, materiais para construção, estando sujeito a forte pressão de uso, o que leva ao assoreamento e a degradação de certos trechos.

Em relação à flora, esta unidade abriga extensos bosques de mangue da APA apresentando uma altura média em torno de 6m, com espécies de vegetação típicas dessas áreas. Essa composição florística constitui quatro espécies que varia de acordo com o tipo de sedimento, tal qual influência na composição e na estrutura dos bosques. São elas:

- *Rizophora mangle* (mangue vermelho) que é a espécie dominante na estrutura da vegetação chegando até ao limite da terra firme;

- *Languncularia racemosa* (mangue branco) passa a dominar na estrutura do bosque indo na direção da terra firme, pois os sedimentos nessa faixa contêm um pouco mais de areia, tornando-se argilo-arenosos;
- *Avicennia Schaueriana* (mangue preto) que predomina onde a salinidade das águas e o teor de areia dos solos são mais altos, nas proximidades do mar;
- *Conocarpus erectus* (mangue de botão) ocorre nos trechos mais elevados nas margens do manguezal mais próxima da terra firme e geralmente forma populações pouco numerosas (FADURPE/CPRH, 2010b).

Desta forma, a APA Santa Cruz caracteriza-se como uma região importante e que deve ser monitorada constantemente para a observação das mudanças ocorridas por ações naturais e antrópicas para ajudar na tomada de decisão da proteção desses recursos naturais.

4.2 AQUISIÇÃO DE DADOS

Para a execução das classificações supervisionadas foram baixadas uma imagem óptica *Landsat-5/TM* e duas imagens de radar *ALOS/PALSAR* que cobriam a área de estudo. Além disto, foram adquiridos o zoneamento das unidades de conservação homogêneas (UAH's) da APA de Santa Cruz em formato vetorial (ESRI *shapefile*) por meio da CPRH e as classes de uso e cobertura do solo dessa região através do MapBiomias.

Para o pré-processamento das imagens, classificações supervisionadas e avaliação da acurácia foi utilizado o software QGIS versão 3.10.12 *A Coruña*, com instalação adicional do complemento *Semi-Automatic Classification plugin (SCP)*. O QGIS ainda foi utilizado como plataforma para a produção dos mapas temáticos. Além disso, foi necessária a instalação do *software SNAP/STEP* para habilitar a classificação *Random Forest* no QGIS.

Em resumo, os materiais utilizados no desenvolvimento deste trabalho foram:

- a) uma imagem *Landsat-5/TM* com data de aquisição de 06/09/2010;
- b) duas imagens *ALOS/PALSAR*, ambas com datas de aquisição de 24/09/2010;
- c) zoneamento das UAH's em formato vetorial (CPRH);
- d) classes de uso e cobertura do solo do ano de 2010 (MapBiomias);
- e) *software* QGIS versão 3.10.12 - *A Coruña*;
- f) *Semi-Automatic Classification plugin (SCP)* versão 7.0.0;
- g) *software* SNAP/STEP versão 8.0;
- h) *Google Earth Pro*;

A imagem *Landsat-5/TM* foi adquirida no repositório de imagens da USGS (*United States Geological Survey*) levando em consideração a presença de nuvens na região da APA de Santa Cruz e o seu nível de processamento. Optou-se, portanto, em fazer o *download* de uma imagem da coleção 2 (*Landsat Collection 2*) e nível de processamento 2 (*Level-2*). Esta coleção possui, por exemplo, melhorias nas imagens em relação a acurácia da geometria, ao modelo digital de elevação e a calibração radiométrica quando comparadas a coleção 1. Além disso, o nível de processamento 2, gera imagens denominadas de produtos científicos, que já se apresentam calibrados em reflectância e temperatura de superfície. Essas imagens são geradas utilizando um *software* especializado chamado LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*) (USGS 2015). O LEDAPS usa o modelo de transferência radiativa 6S para reduzir efeitos atmosféricos, como espalhamento e absorção, nas imagens Landsat/TM (MASEK et al. 2006).

As características desta imagem podem ser observadas no quadro 2 abaixo:

Quadro 2 - Principais características da imagem Landsat-5/TM utilizada

Nome do produto	LT05_L2SP_214065_20100906_20200823_02_T1
Sensor/Satélite	TM/Landsat-5
Data e hora de aquisição	06/09/2010 - 12:19:18 (GMT)
Path/Row	214/065
Nível de Processamento	2
Coleção	2
Tipo de Produto	<i>Science Product - Surface Reflectance</i>
Bandas	1-5,7(BLUE, RED, GREEN, NIR, SWIR1 e SWIR 2)
Direção de voo	Descendente
Resolução espacial (m)	30
Tipo de dado	Uint16

Fonte: Metadados da imagem/ USGS, 2010.

Já as imagens SAR, foram adquiridas no ASF (*Alaska Satellite Facilities*) *data search*. Lá foram pesquisadas e baixadas duas imagens do sensor ALOS/PALSAR do mesmo ano da imagem óptica, com nível processamento RTC (*Radiometric Terrain Corrected*) compreendendo a mesma área de estudo. Estes produtos (RTC) são disponibilizados no formato “GeoTiff” e apresentam ambas as correções geométricas e radiométricas, tornando-os assim, mais acessíveis a comunidade de usuários. Além disso, essas imagens são disponibilizadas nas resoluções espaciais de 12,5m (*high resolution*) e 30m (*low resolution*), sendo esta última compatível com as resoluções das imagens Landsat-5/TM.

As especificações das imagens SAR baixadas podem ser observadas nos quadros abaixo (quadros 3 e 4).

Quadro 3 - Principais características da primeira imagem ALOS/PALSAR utilizada

Nome do produto	ALPSRP248557030
Sensor/Satélite	PALSAR/ALOS
Data e hora de aquisição	24/09/2010 - 01:11:02 (GMT)
Frequência (GHz)	1,27
Comprimento de onda (cm)	23,6
Modo	FBD - <i>Fine Beam Dual</i>
Polarizações	HH+HV
Nível de Processamento	RTC - <i>Radiometric Terrain Corrected</i>
Direção de voo	Ascendente
Resolução espacial (m)	30 (<i>low resolution</i>)
Tipo de dado	Float32

Fonte: Metadados da imagem/ASF, 2010.

Quadro 4 - Principais características da segunda imagem ALOS/PALSAR utilizada

Nome do produto	ALPSRP248557020
Sensor/Satélite	PALSAR/ALOS
Data e hora de aquisição	24/09/2010 - 01:10:54 (GMT)
Frequência (GHz)	1,27
Comprimento de onda (cm)	23,6
Modo	FBD - <i>Fine Beam Dual</i>
Polarizações	HH+HV
Nível de Processamento	RTC - <i>Radiometric Terrain Corrected</i>
Direção de voo	Ascendente
Resolução espacial (m)	30 (<i>low resolution</i>)
Tipo de dado	Float32

Fonte: Metadados da imagem/ASF, 2010.

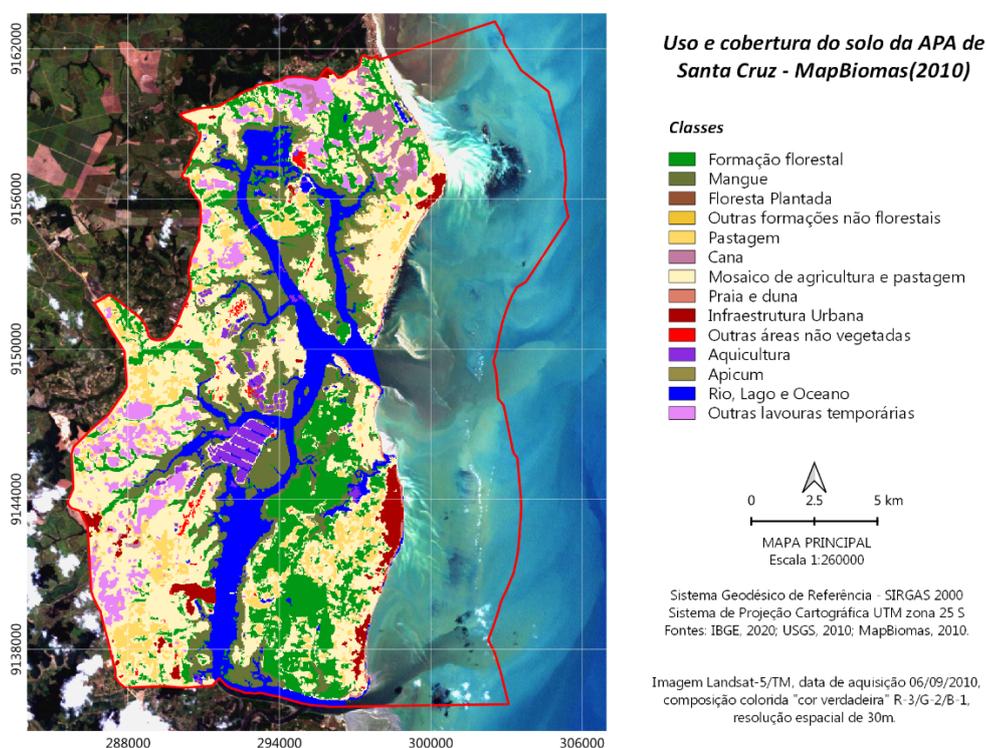
Para a utilização de imagens de radar em ambientes costeiros é importante a aquisição da informação do nível da maré no momento da aquisição da imagem. Nesta data, a partir de dados da Diretoria de Hidrografia e Navegação da Marinha do Brasil (DHN) a maré se encontrava seca, com valores próximos ao de 0,4m na estação maregráfica do Porto do Recife (que dista aproximadamente 27km da APA de Santa Cruz).

Foram necessárias duas imagens de radar para a cobertura da área de estudo. Desta forma, foi necessário realizar uma mosaicagem entre essas duas imagens para prosseguir com as etapas posteriores.

Devido ao fato de o vetor da UAH-5 estar relacionado com o ecossistema manguezal como um todo, foi necessária a utilização de dados de outra fonte para quantificar o mangue existente na APA. Por isso, foram adquiridos dados da série histórica do Mapbiomas (Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil) que é uma iniciativa com finalidade de gerar uma série histórica de mapas anuais de uso e cobertura da terra, contribuindo para o entendimento da dinâmica do uso do solo no Brasil e em outros países tropicais (Mapbiomas, 2021).

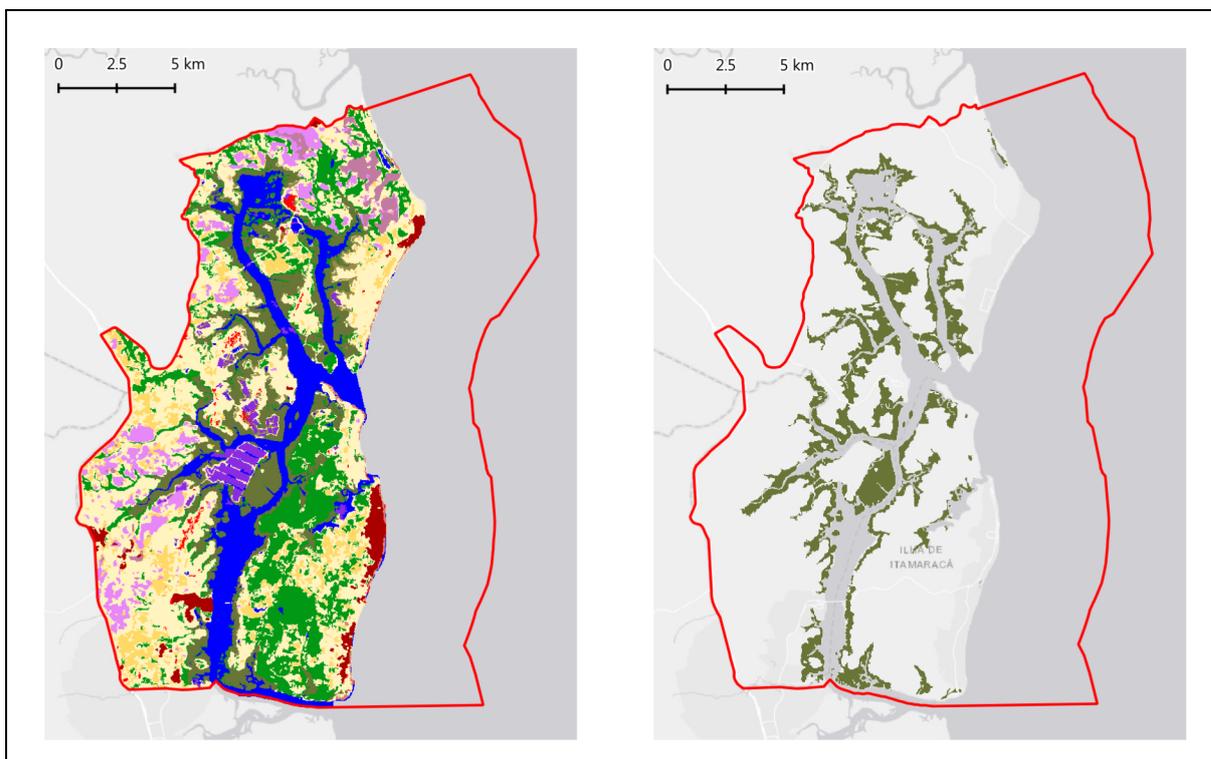
Desta forma, foram baixadas em formato raster as classes de uso e ocupação do solo do bioma Mata Atlântica do ano de 2010 (coleção 5) e estas informações foram recortadas para APA de Santa Cruz (figura 15). Após o recorte a classe de mangue foi selecionada e sua área foi calculada, resultando em 3476,35ha para o ano citado (figura 16).

Figura 15 - Uso e cobertura do solo da Aapa de Santa Cruz utilizando dados do Mapbiomas



Fonte:O autor, 2021.

Figura 16 - Seleção da classe "mangue" (à direita) em relação as classes de uso e cobertura da APA de Santa Cruz – 2010 (à esquerda)



Fonte: O autor, 2021.

4.3 PRÉ-PROCESSAMENTO

Nesta seção será abordado o pré-processamento, que consiste em um conjunto de atividades de preparação, organização e estruturação dos dados. Aqui serão apresentadas as etapas de preparação das imagens adquiridas para classificação supervisionada, sendo elas: a definição dos *bandsets* de classificação, conversão radiométrica, geoprocessamento (empilhamento, recorte e reprojeção) e o cálculo dos índices físicos.

4.3.1 Definição dos *bandsets* de classificação

Esta etapa se referiu a definição de cada conjunto de dados a ser classificado pelos algoritmos MaxVer e RF. Foram definidos, portanto, 4 conjuntos de dados (nomeados aqui de “*bandsets*”) gerados a partir da combinação de informações das bandas da imagem óptica, da imagem SAR e dos índices de vegetação (NDVI, SAVI e NDWI). O critério escolhido para essa combinação foi introduzir informações de outras fontes à imagem óptica e assim

observar o desempenho de cada classificador com o acréscimo de informações diferentes. As combinações geradas podem ser observadas na tabela 4, abaixo.

Tabela 4 - Definição dos *bandsets* para classificação

Número do <i>bandset</i>	Combinação de bandas	Quantidade de bandas	Descrição
1	TM	6	TM1-5,7;
2	TM+SAR	9	TM1-5,7, HH, HV, HH/HV;
3	TM+ÍNDICES	9	TM1-5,7, NDVI, NDWI, SAVI.
4	TM+SAR+ÍNDICES	12	TM1-5,7, HH, HV, HH/HV, NDVI, NDWI, SAVI.

Fonte: O autor, 2021.

As etapas seguintes de pré-processamento estão relacionadas a construção e preparação desses *bandsets* para classificação.

4.3.2 Conversão Radiométrica

A conversão radiométrica das imagens foi realizada a fim de transformar o número digital armazenado nos pixels em unidades físicas. Desta forma a imagem Landsat-5/TM, por ser um produto científico já calibrado em reflectância de superfície, tem seus números digitais convertidos de forma linear por meio da equação 16:

$$\rho_{\lambda} = M_{\rho} * Q_{cal} + A_{\rho} \quad (16)$$

Onde,

ρ_{λ} : reflectância de superfície (calculada pelo algoritmo LEDAPS);

M_{ρ} : fator de redimensionamento multiplicativo específico por banda, presente no arquivo de metadados da imagem ($M_{\rho} = 0,0000275$);

A_{ρ} : fator de redimensionamento aditivo específico por banda, presente no arquivo de metadados da imagem ($A_{\rho} = -0,2$);

Q_{cal} : valores do pixel quantificados e calibrados de produtos padrão (número digital);

Já para os dados SAR, as imagens RTC são disponibilizadas com calibração em γ^0 , que é a razão entre a potência que volta de uma porção do terreno e a potência emitida para esta mesma porção de terreno. Este tipo de dado suporta avaliações estatísticas, entretanto, quando exibidos no software GIS, a imagem aparece escura, o que dificulta a sua utilização para análise visual. Desta forma, a imagem foi convertida de γ^0 para “dB” (decibéis) visto que é uma unidade que melhora a visualização e distribuição dos dados e tem boa documentação nas bibliografias estudadas.

A conversão entre essas unidades pode ser realizada a partir da equação 17.

$$X_{(dB)} = 10 * \log_{10}(X_{\gamma^0}) \quad (17)$$

onde,

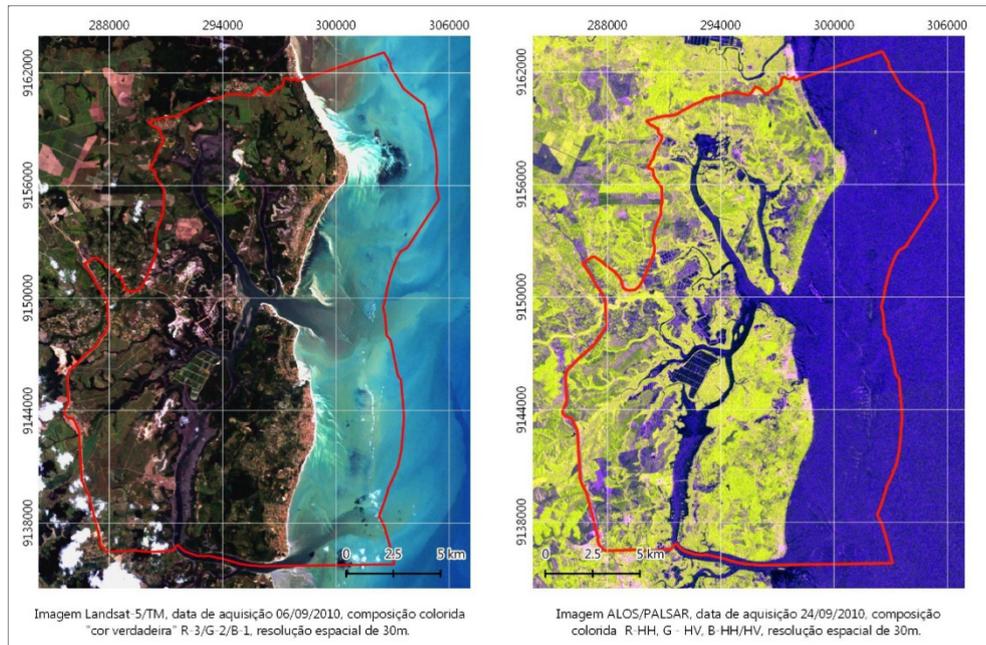
$X_{(dB)}$: Imagem intensidade com valores expressos em decibéis(dB);

X_{γ^0} : Imagem intensidade com valores expressos em γ^0 ;

4.3.3 Geoprocessamento

Esta etapa compreende o empilhamento, recorte e reprojeção das imagens utilizadas. Depois das imagens terem sido convertidas radiometricamente, elas foram empilhadas, ou seja, as bandas de cada sensor foram agrupadas em um único arquivo, gerando, inicialmente, um *stack* para o Landsat-5/TM e um para o ALOS/PALSAR. Composições coloridas feitas a partir desses dois produtos iniciais podem ser vistas na figura 17.

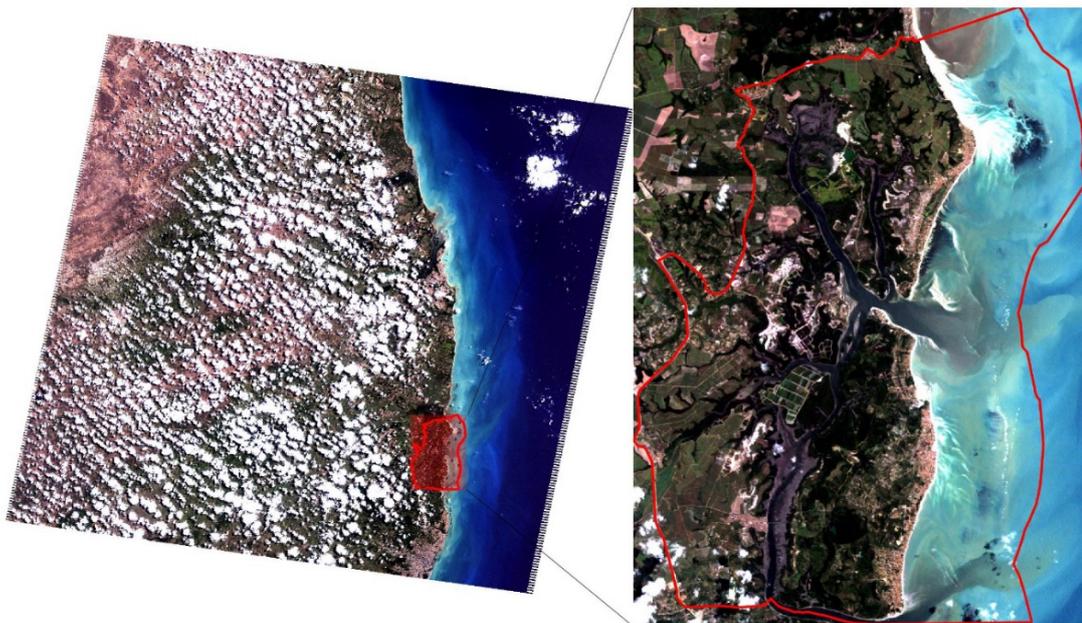
Figura 17 - Composições coloridas geradas a partir do empilhamento das bandas dos sensores TM e PALSAR



Fonte: O autor, 2021.

Devido às diferenças existentes entre as imagens TM e PALSAR em relação as suas dimensões, elas foram recortadas para ficarem com as mesmas extensões. Para este fim, utilizou-se como referência os limites máximos da extensão geográfica do vetor da APA de Santa Cruz, como pode ser visto na figura 18.

Figura 18 - Recorte da área de estudo utilizado para classificação



Fonte: O autor, 2021.

Após recorte, os *bandsets* foram reprojatados para o Sistema Geodésico de Referência vigente no Brasil que é o SIRGAS2000, utilizando o sistema de projeção Universal Transverso de Mercator (UTM) zona 25 Sul.

4.3.4 Cálculo dos índices físicos

Os índices físicos foram calculados baseados nas equações 3, 4 e 5, mostradas na seção 3.3.1. Utilizando a calculadora de campo do QGIS e substituindo as variáveis das equações pelas bandas do sensor TM, tem-se:

a) NDVI

$$NDVI = \frac{TM_4 - TM_3}{TM_4 + TM_3} \quad (18)$$

Onde,

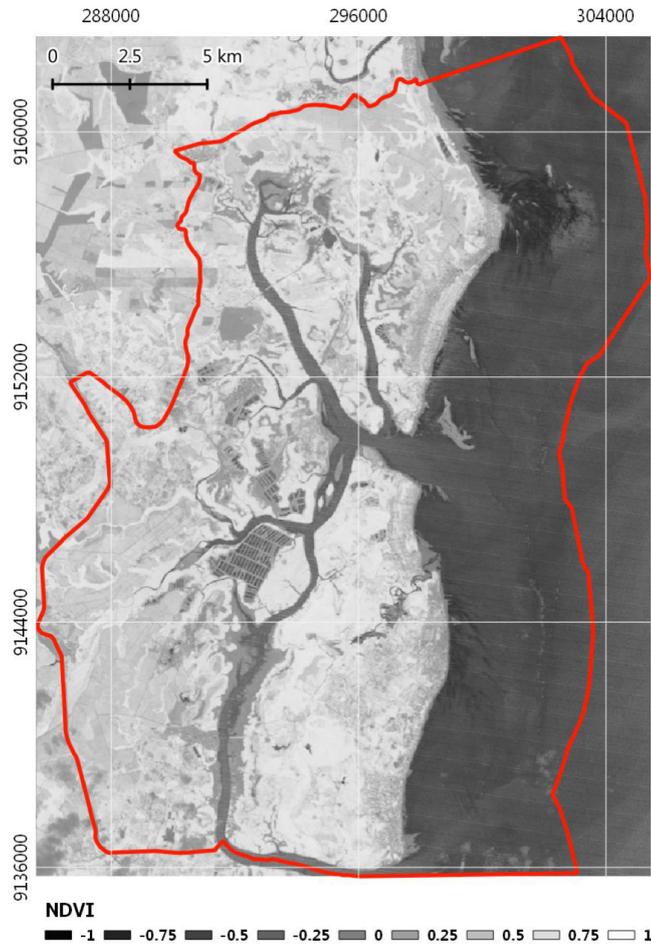
NDVI: índice de vegetação por diferença normalizada.

TM₄: banda 4 do sensor TM referente a região espectral do infravermelho próximo;

TM₃: banda 3 do sensor TM referente a região espectral do vermelho;

A imagem resultante do cálculo do NDVI pode ser vista na figura 19.

Figura 19 - NDVI da área de estudo



Fonte: O autor, 2021.

b) NDWI

$$NDWI = \frac{TM_4 - TM_5}{TM_4 + TM_5} \quad (19)$$

Onde,

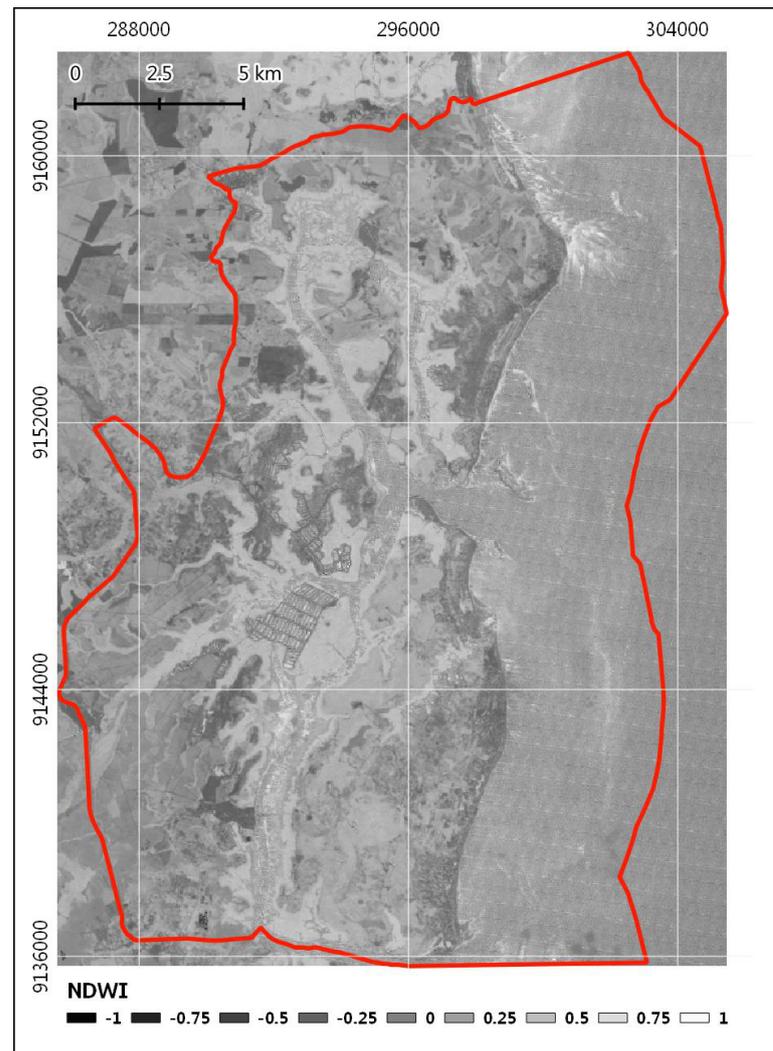
NDWI: índice de umidade por diferença normalizada;

TM₄: banda 4 do sensor TM referente a região espectral do infravermelho próximo;

TM₅: banda 3 do sensor TM referente do infravermelho médio (SWIR 1);

A imagem resultante do cálculo do NDWI pode ser vista na figura 20.

Figura 20 - NDWI da área de estudo



Fonte: O autor, 2021.

c) SAVI

$$SAVI = \frac{(TM_4 - TM_3) * (1 + L)}{TM_4 + TM_3 + L} \quad (20)$$

Onde,

SAVI: índice de vegetação ajustado para o solo;

TM₄: banda 4 do sensor TM referente a região espectral do infravermelho próximo;

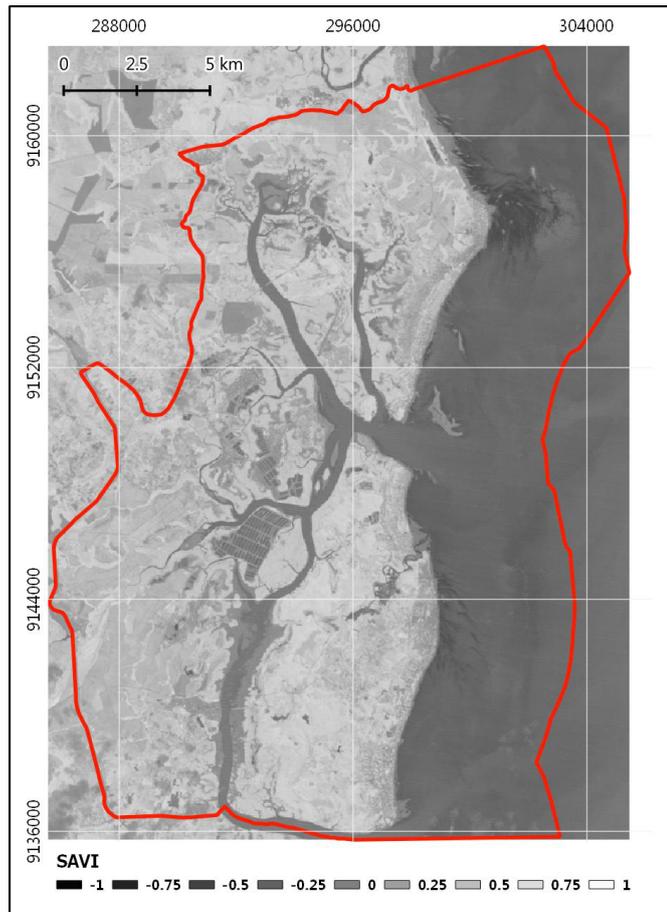
TM₃: banda 3 do sensor TM referente a região espectral do vermelho;

L: constante que minimiza o efeito do solo.

Para este trabalho foi adotado o valor de $L = 0,16$ devido a estudos que apresentam bons resultados para detecção de mangue com este valor (SILVA, 2012).

A imagem resultante do cálculo do SAVI pode ser vista na figura 21.

Figura 21 - SAVI da área de estudo



Fonte: O autor, 2021.

Além do cálculo dos índices físicos, foi gerada uma divisão entre as bandas HH e HV da imagem ALOS/PALSAR, o que proporcionou mais uma informação a ser acrescentada nas classificações.

4.4 CLASSIFICAÇÃO SUPERVISIONADA

Aqui são abordadas todas as etapas referentes à execução da classificação supervisionada propriamente dita. As etapas são: definição das classes de ocupação do solo, amostragem e classificação.

4.4.1 Definição das classes

As classes de cobertura do solo foram definidas baseando-se nos principais alvos existentes na região de estudo com o auxílio das delimitações das UAH's. Foram definidas, portanto, 12 (doze) classes para a classificação, como pode ser visto no quadro 5.

Quadro 5 - Definição e descrição das classes para classificação

Macroclasses	Classes	Descrição
Mangue	Mangue	Bosques ou florestas de mangue.
Não mangue	Mata Atlântica	Vegetação de mata atlântica, presente em várias unidades de conservação na APA.
	Área Urbana	Áreas consolidadas ou de expansão urbana que concentram maior parte da população.
	Área Antropizada	Áreas referentes a pastagens, áreas degradadas, assentamentos, culturas de cana-de-açúcar, coco policultura e silvicultura.
	Areia	Areia de praia, bancos de areia.
	Solo Exposto 1	Solos exposto de tonalidade clara.
	Solo Exposto 2	Solo exposto de tonalidade intermediária.
	Solo Exposto 3	Solo exposto de tonalidade escura.
	Rio	Corpos hídricos.
	Oceano	Ambiente marinho.
	Nuvem	Nuvens.
Sombras	Sobra de nuvens.	

Fonte: O autor, 2021.

Como o objetivo do estudo é mapear as apenas o mangue, as demais classes foram agrupadas em uma única classe denominada “não-mangue” (quadro 5). Na prática, isso faz com que algoritmo reclassifique automaticamente todas as outras classes diferentes de mangue em uma única classe.

4.4.2 Amostragem

As amostras de treinamento para as classificações foram coletadas usando o SCP, que possui ferramentas específicas para esta finalidade. A amostragem foi realizada atribuindo rótulos de classes e macroclasses para cada vetor coletado e aquisição desses vetores foi realizada pensando em atender as especificações de cada classificador, principalmente em

relação a quantidade de pixels amostrados. É importante ressaltar que as amostras de treinamento coletadas foram as mesmas para cada classificação, a fim de possibilitar a comparação entre os resultados em cada classificador.

Ao todo, foram coletados 7135 pixels como amostras de treinamento para classificação, adquirindo de 600 a 700 pixel no total para cada classe. Como a amostragem depende da existência do alvo na cena classificada, algumas classes não chegaram a totalizar um número de 600 pixels.

A figura 22 apresenta a espacialização dos vetores utilizados para treinamento dos classificadores e o quadro 6 a quantidade de amostras para cada classe.

Figura 22 - Espacialização das amostras de treinamento por classe



Fonte: O autor, 2021.

Para cada classificação, foi utilizada as mesmas amostras de treinamento, o que é de extrema importância para que os resultados gerados possam ser comparados.

Quadro 6 - Quantidade de amostras (pixels) por classe

Macroclasses	Classes	Quantidade de pixels
Mangue	Mangue	666
Não mangue	Mata Atlântica	641
	Área Urbana	646
	Área Antropizada	674
	Areia	545
	Solo Exposto 1	536
	Solo Exposto 2	657
	Solo Exposto 3	610
	Rio	614
	Oceano	623
	Nuvem	631
	Sombras	292
	Total de amostras =	7135

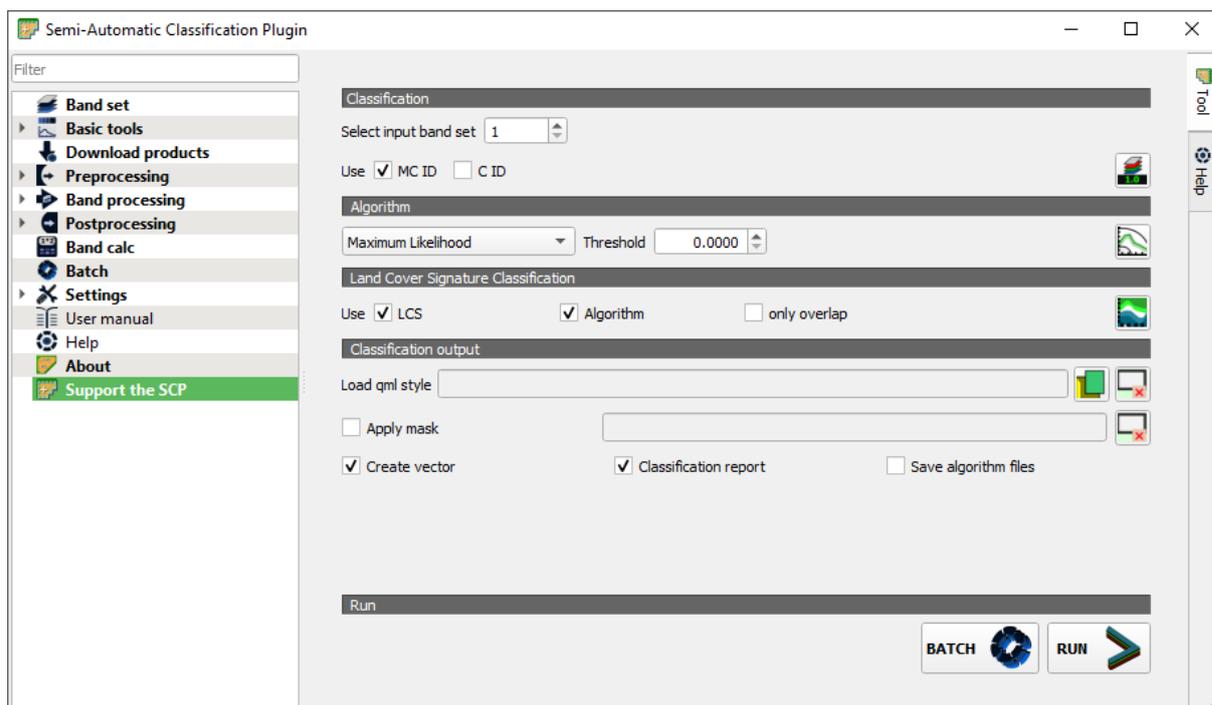
Fonte: O autor, 2021.

4.4.3 Máxima Verossimilhança

Como o SCP já possui o classificador MaxVer implementado em suas ferramentas, para realizar a classificação é necessário apenas carregar as amostras de treinamento e indicar o *bandset* a ser classificado. Desta forma, foram classificados todos os 4 *bandsets* criados previamente, utilizando a mesma amostra de treinamento.

Para realizar a comparação entre os resultados, é necessário que além das amostras de treinamento, os parâmetros de classificação sejam os mesmos. Devido a isto, alguns parâmetros precisam ser configurados para a realização da classificação, como por exemplo, o limiar de aceitação. Para que todos os pixels na imagem fossem classificados, o limiar de aceitação foi definido como 0 (zero) para todos os *bandsets*. As configurações definidas para classificações com Máxima Verossimilhança podem ser vistas na figura 23.

Figura 23 - Painel de classificação do MaxVer no SCP



Fonte: O autor, 2021.

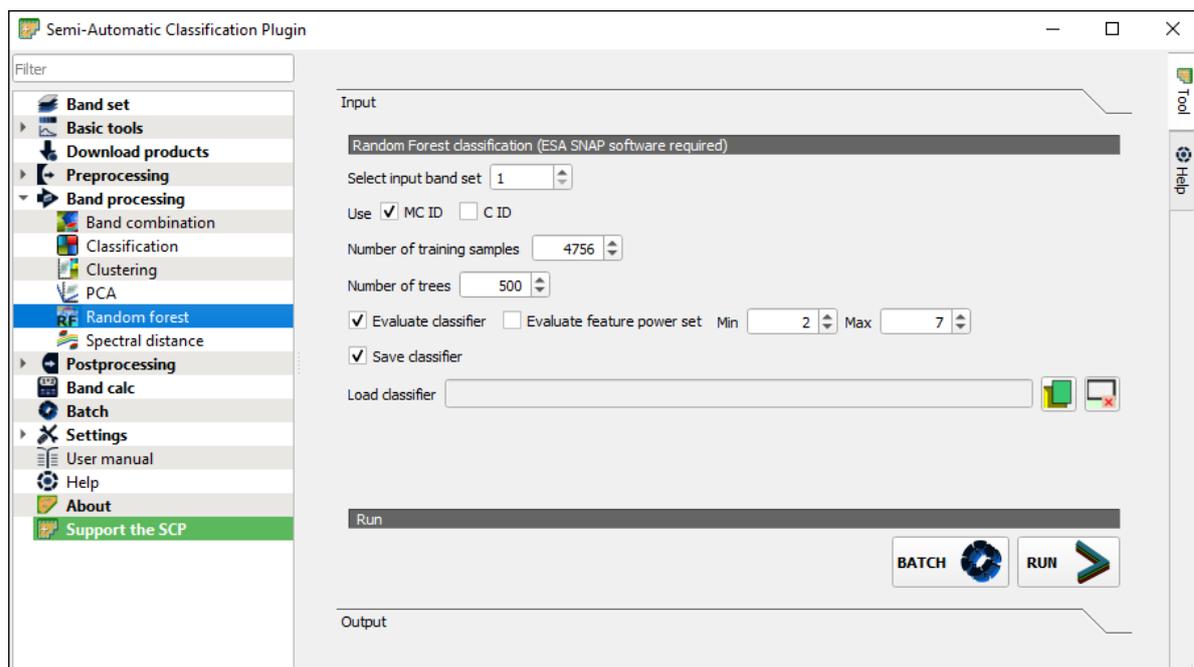
É importante frisar que, verificando em Congedo (2020), a matemática implementada pelo SCP para este classificador está em concordância com o que foi apresentado na seção 3.4.1.

4.4.4 Random Forest

A classificação por *Random Forest* exigiu, primeiramente, que fosse indicado ao SCP o diretório que contém o arquivo executável do SNAP. Desta forma, é necessário que o SNAP esteja instalado e funcionando corretamente para que a classificação usando o SCP seja possível - já que ele não possui este algoritmo diretamente implementado em suas ferramentas. Entretanto, não é necessário inicializar o SNAP para realização a classificação.

Assim como no MaxVer, é necessário manter os parâmetros de classificação do *Random Forest* idênticos a cada processamento. Por isto, dos parâmetros existentes, foram definidos como fixos o número de amostras aleatórias (4756) – o que equivale a 2/3 (dois terços) das amostras de treinamento - e o número de árvores geradas ($N_{tree} = 500$) a cada classificação, podendo esses parâmetros serem vistos na figura 24.

Figura 24 - Painel de classificação do Random Forest no SCP



Fonte: O autor, 2021.

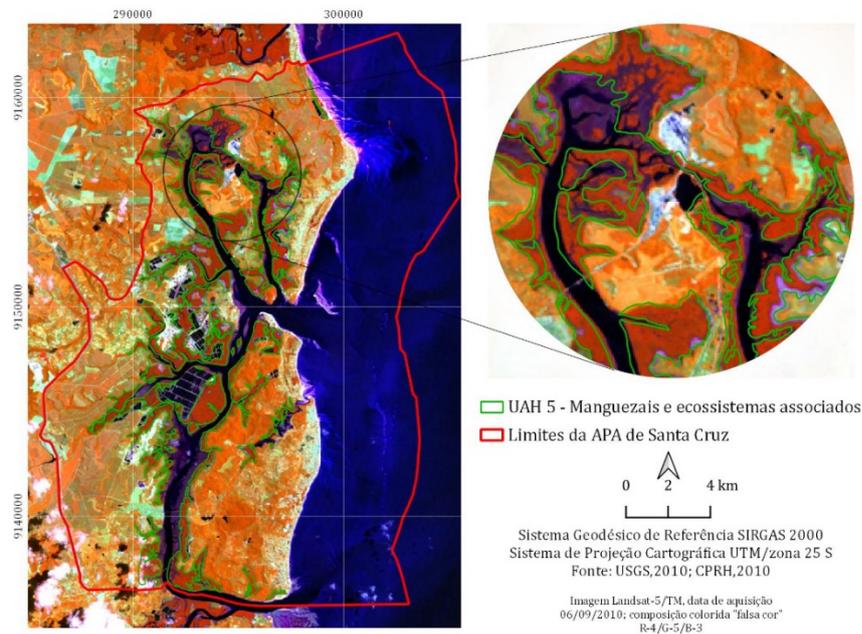
4.5 AVALIAÇÃO DA ACURÁCIA DAS CLASSIFICAÇÕES

Nesta seção serão abordados os procedimentos metodológicos executados para avaliação de acurácia das classificações.

4.5.1 Aquisição de amostras de validação

Neste trabalho, o dado de referência que seria utilizado para validação das classificações seria o vetor referente a UAH-5, disponibilizado pela CPRH. Entretanto, como dito anteriormente, a definição dessa UAH se caracteriza como “Manguezais e ecossistemas associados”, implicando na existência de várias regiões dessa camada vetorial que não se referem apenas aos bosques de mangue, e sim a outros elementos do ecossistema, além de apresentar pouca qualidade posicional quando observado em sobreposição a imagem (figura 25).

Figura 25 - Espacialização do vetor referente a UAH 5 e divergências entre o vetor e a imagem



Fonte: O autor, 2021.

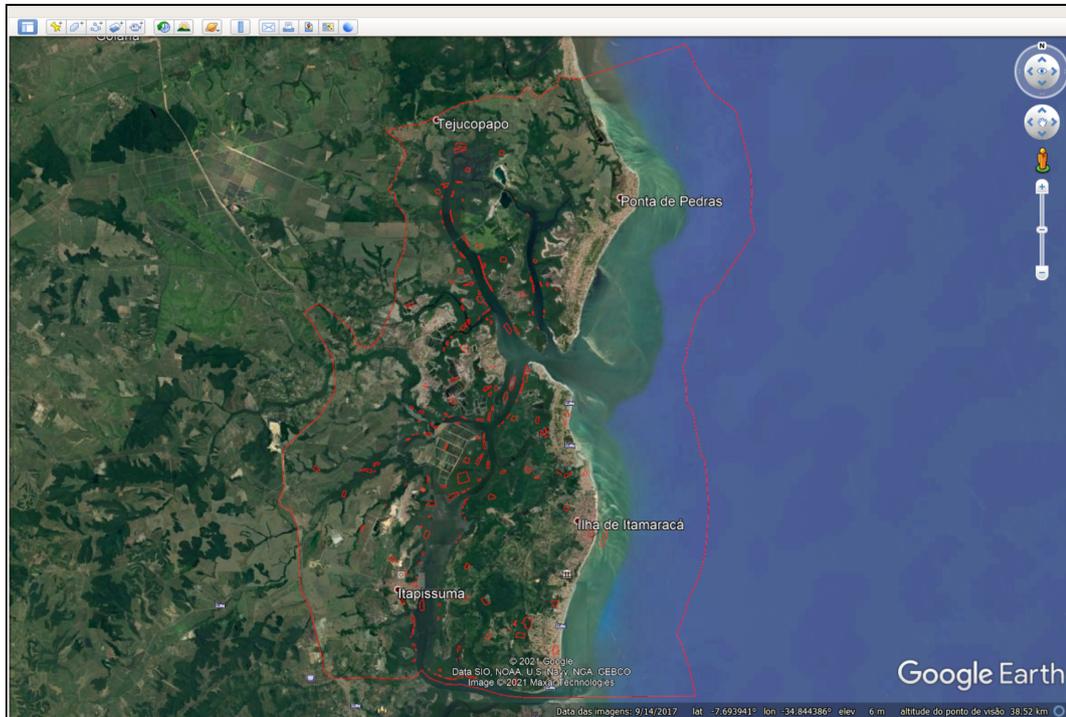
Na figura 25, é possível perceber que o vetor referente a UAH-5(em verde) cobre áreas na imagem que não são vegetação, mas que pertencem ao ecossistema. Desta forma, para evitar erros relacionados a pixels que não correspondem a macroclasse “mangue” nas amostras de validação que induzissem a erros na matriz de confusão, decidiu-se usar o *Google Earth Pro* como ferramenta de aquisição dessas amostras. Essa ferramenta se apresenta bastante útil porque, além de apresentar imagens com melhor resolução espacial, o que facilita a fotointerpretação, também dá acesso série histórica de imagens do *Google*, permitindo sua utilização como referência para a coleta das amostras.

Assim, utilizando imagens da série histórica datadas de agosto de 2010, foram coletados vários polígonos como amostras de validação, delimitando regiões referentes as macroclasses por meio de interpretação visual. É importante ressaltar que estas amostras foram coletadas apenas dentro da delimitação da APA de Santa Cruz apesar do recorte geográfico da imagem apresentar uma extensão um pouco maior. Além disso, embora o vetor da UAH-5 não tenha sido utilizado com dados de referência para a avaliação da acurácia das classificações, ele auxiliou a coleta de amostras referentes aos bosques de mangue, já que eles poderiam ser encontrados no interior desses polígonos.

Os polígonos, por fim, foram definidos de forma a não coincidirem com as amostras de treinamento e foram todos reprojatados para o mesmo sistema geodésico de referência do projeto (SIRGAS2000/UTM 25S). Ao todo foram coletados 4156 pixels para a validação da

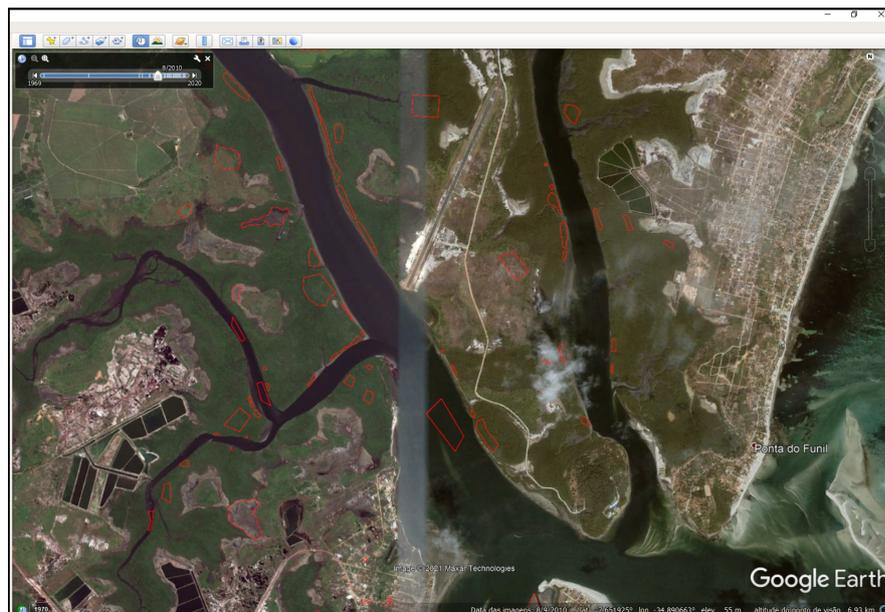
classificação, que representam cerca 37% em relação ao todo (amostras de treinamento + amostras de validação). As figuras 26 e 27 mostram as amostras utilizadas, destacados como pequenos polígonos vermelhos.

Figura 26 - Espacialização das amostras de validação no Google Earth Pro



Fonte: O autor, 2021.

Figura 27 - Aquisição de amostras de avaliação no *Google Earth Pro* utilizando a série histórica

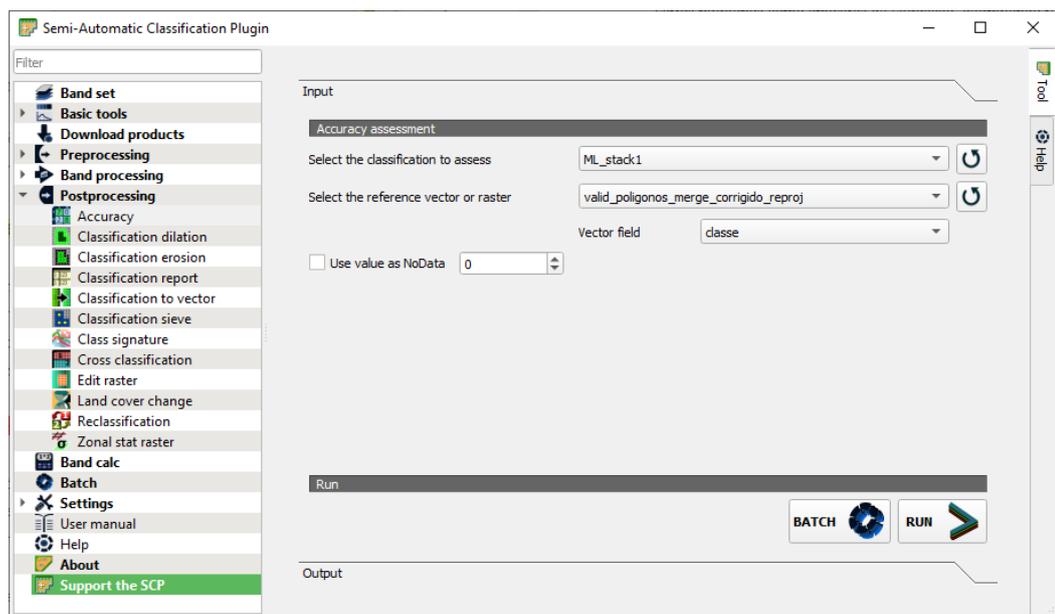


Fonte: O autor, 2021.

4.5.2 Estatísticas de Avaliação

A avaliação da acurácia das classificações foi realizada por meio de relatório estatístico gerado pelo próprio SCP a partir da ferramenta “*Accuracy*”. Para isto é necessário indicar no *plugin* a imagem classificada, os dados de referência e o campo presente nos dados de referência que será comparado com a classificação, como pode ser observado na figura 28.

Figura 28 – Painel de avaliação de acurácia do SCP



Fonte: O autor, 2021.

É importante ressaltar que, de acordo com a documentação do SCP, as estatísticas geradas pela ferramenta estão em consonância com o que foi mostrado na seção 3.5.

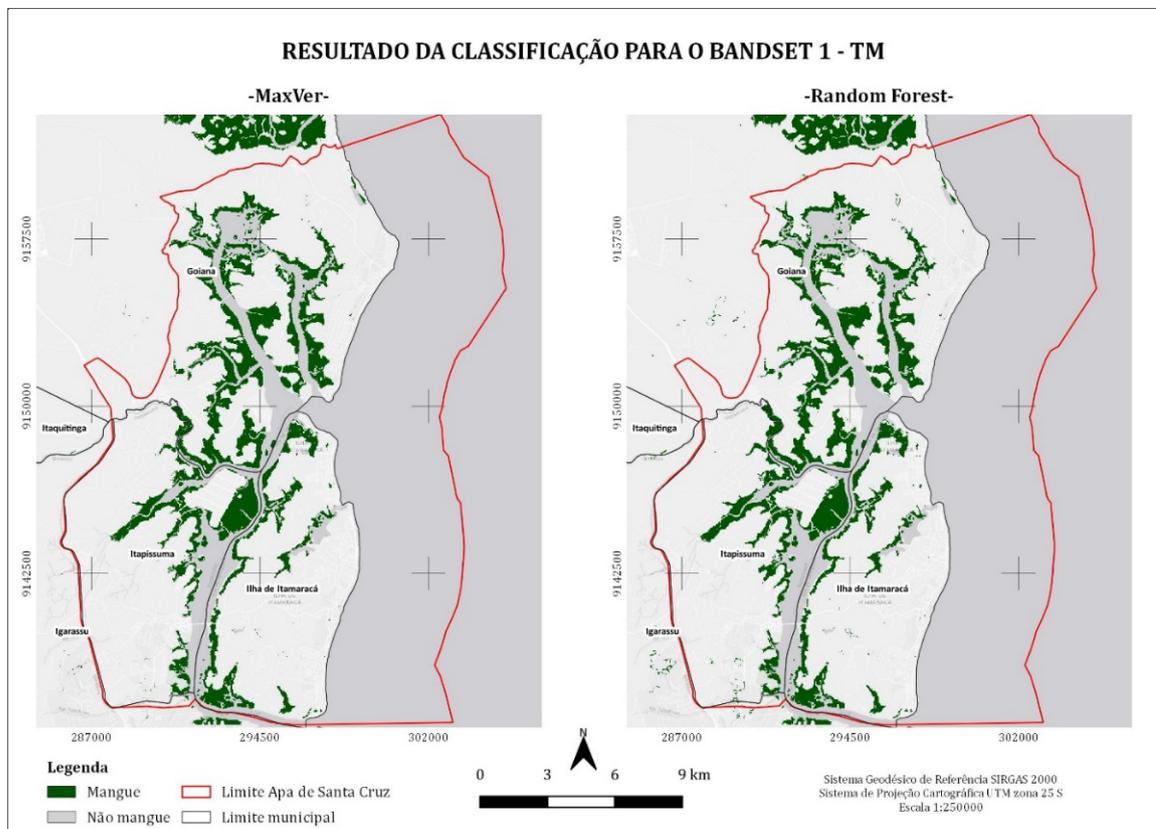
5 RESULTADOS E DISCUSSÕES

Os resultados obtidos por meio das classificações supervisionadas dos *bandsets* por meio dos classificadores MaxVer e *Random Forest* estão exibidos nesta seção. Para facilitar a visualização e entendimento de cada resultado separadamente, eles foram organizados por *bandset* e, ao fim, foi realizada uma comparação entre eles em termos de acurácia global, índice kappa, área e mapeamento temático. Além disso, todos os mapas gerados aqui estão presentes no apêndice do trabalho para melhor visualização.

5.1 CLASSIFICAÇÕES DO *BANDSET* 1

O mapa gerado a partir do resultado das classificações do *bandset* 1 pelos classificadores supervisionados Máxima Verossimilhança e *Random Forest* podem ser visualizados na figura 29.

Figura 29 - Resultado da classificação do *bandset* 1 utilizando os classificadores Máxima Verossimilhança e Random Forest



Fonte: O autor, 2021.

A partir da figura 29 é possível perceber visualmente o desempenho semelhante entre os dois classificadores. Isto deve-se ao fato deste bandset ser formado apenas por bandas do sensor TM, o que garante que as classes tenham distribuição estatística que se aproxima da distribuição normal. Esse desempenho semelhante se confirma quando analisados os resultados estatísticos da classificação adquiridos através dos relatórios de processamento do SCP (tabelas 5 e 6).

Tabela 5 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset 1* por MaxVer

Matriz de erro - Bandset 1 - Maxver					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,087	0,002	34389900	0,089
	Não mangue	0,039	0,873	353168100	0,911
	Total	0,126	0,874	387558000	
	Área (m ²)	48737126	338820874	387557999	
SE		0,0039	0,0039		
SE área		1527235	1527235		
95% CI área		2993380	2993380		
PA [%]		69,20	99,80		
UA [%]		98,07	95,75		
Kappa hat		0,98	0,66		
Overall accuracy [%] =		95,96			
Kappa hat classification =		0,79			

Fonte: O autor, 2021.

Tabela 6 – Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset 1* por *Random Forest*

Matriz de erro - Bandset 1 - Random Forest					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,088	0,002	34753500	0,090
	Não mangue	0,041	0,870	352804500	0,910
	Total	0,129	0,871	387558000	
	Área (m ²)	49846739	337711261	387557999	
SE		0,004	0,004		
SE área		1560718	1560718		
95% CI área		3059008	3059008		
PA [%]		68,37	99,80		
UA [%]		98,06	95,53		
Kappa hat		0,98	0,65		
Overall accuracy [%] =		95,76			
Kappa hat classification =		0,78			

Fonte: O autor, 2021.

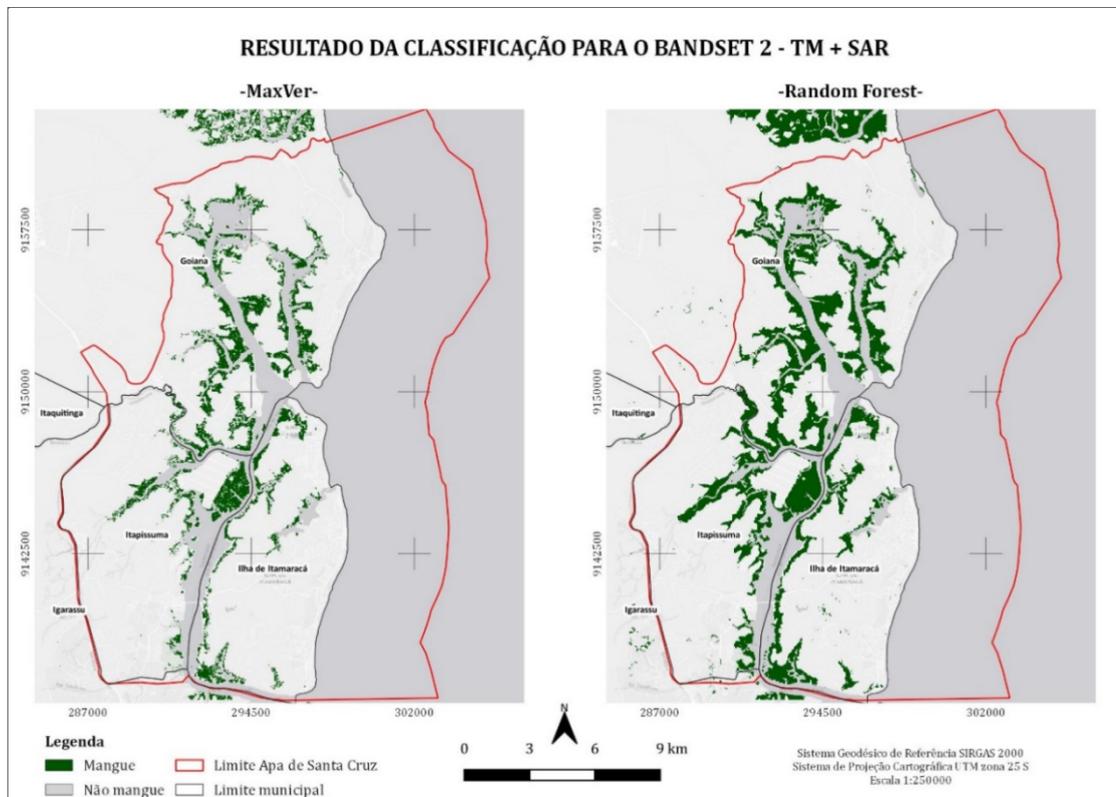
Das tabelas 5 e 6 pode-se verificar as semelhanças entre as acurácias globais, 95,95% e 95,76% respectivamente para o MaxVer e o *Random Forest*, assim como os índices kappa, com valores de 0,79 e 0,78 respectivamente, ambas se enquadrando como desempenhos “muito bons” segundo a divisão proposta por Fonseca (2000). Além disso, é possível perceber uma similaridade entre as acurácias do produtor e do usuário nos dois métodos.

Observa-se também que houve diferenças no cálculo das áreas classificadas referentes aos bosques de mangue existentes na APA. Para o MaxVer a área calculada foi de 3438,99ha enquanto para o RF foi de 3475,35ha, resultando, portanto numa diferença de 36,36ha.

5.2 CLASSIFICAÇÕES DO *BANDSET 2*

Já para o *bandset 2*, combinação entre bandas TM e do PALSAR, foi possível perceber uma redução significativa no desempenho do classificador MaxVer apenas comparando a área mapeada como mangue pelos classificadores (figura 30).

Figura 30 - Resultado da classificação do *bandset 2* utilizando os classificadores Máxima Verossimilhança e *Random Forest*.



Fonte: O autor, 2021.

Nessa figura, observam-se muitas falhas na classificação em relação ao classificador MaxVer, indicando a necessidade, a posteriori, de aplicações de filtragem passa-baixa. Isto pode ser consequência da introdução de dados de fontes diferentes (sensor óptico e radar) na classificação. Por outro lado, também pode-se perceber a consistência existente na classificação por *Random Forest* em relação ao resultado do *bandset* 1. Essas verificações visuais podem ser confirmadas a partir do relatório estatístico mostrado nas tabelas 7 e 8.

Tabela 7 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset* 2 por MaxVer

Matriz de erro - Bandset 2 - Maxver					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,051	0,001	20340000	0,053
	Não mangue	0,223	0,725	367208100	0,948
	Total	0,274	0,726	387548100	
	Área (m ²)	106239552	281308548	387548100	
SE		0,0077	0,0077		
SE área		2971995	2971995		
95% CI area		5825109	5825109		
PA [%]		18,75	99,85		
UA [%]		97,92	76,49		
Kappa hat		0,97	0,14		
Overall accuracy [%] =			77,62		
Kappa hat classification =			0,25		

Fonte: O autor, 2021.

Tabela 8 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset* 2 por *Random Forest*

Matriz de erro - Bandset 2 - Random Forest					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,10	0,00	37723500	0,10
	Não mangue	0,04	0,86	349824600	0,90
	Total	0,14	0,86	387548100	
	Área (m ²)	52880828	334667272	387548100	
SE		0,004	0,004		
SE área		1567247	1567247		
95% CI area		3071805	3071805		
PA [%]		69,77	99,75		
UA [%]		97,80	95,43		
Kappa hat		0,97	0,67		
Overall accuracy [%] =			95,66		
Kappa hat classification =			0,79		

Fonte: O autor, 2021

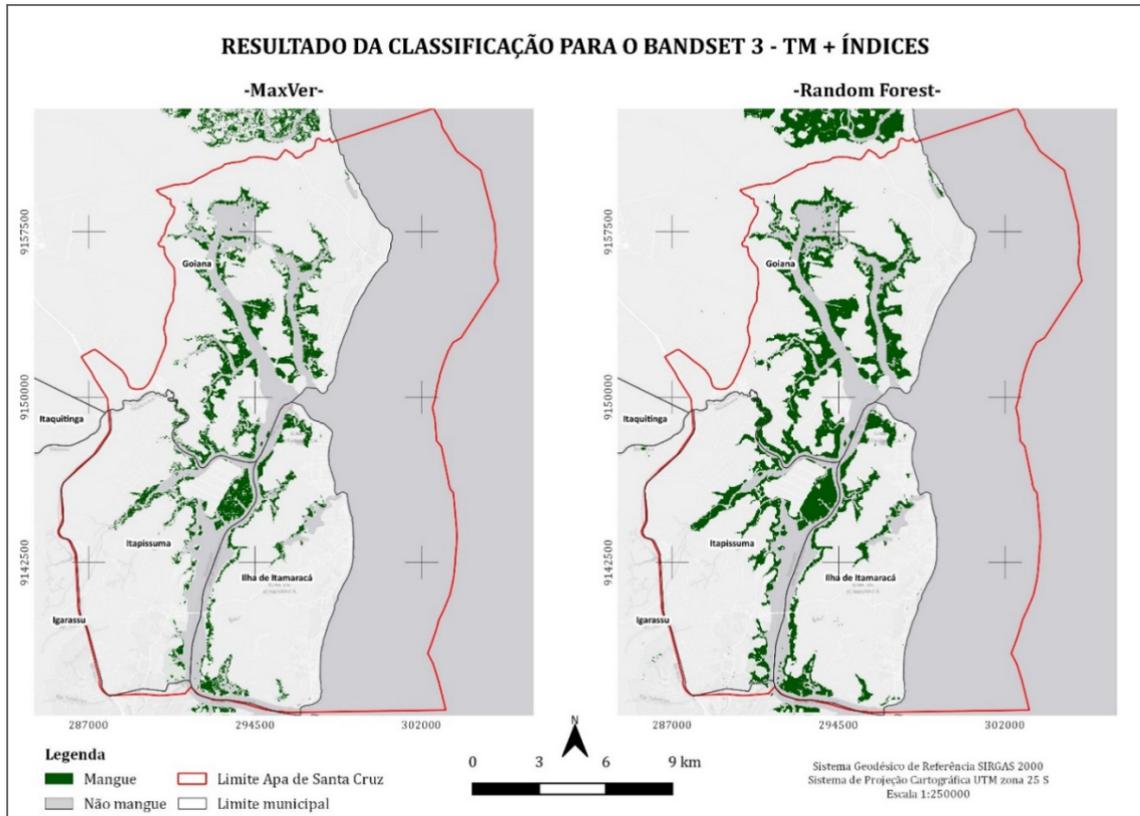
Das tabelas 7 e 8, verifica-se estatisticamente a diminuição do desempenho do classificador MaxVer na classificação do *bandset 2* com valores de 77,62% de acurácia global e 0,25 de índice kappa, incluindo-se, portanto, na categoria de desempenho “razoável”. Além disso, é interessante observar a acurácia do produtor para este classificador no valor de 18,75%, indicando a baixa capacidade do classificador em distinguir as classes. Isto deve-se também ao fato de que a imagem SAR, neste caso específico, não ofereceu informação que permitisse discriminar os alvos.

Em relação a classificação por RF, tem-se uma acurácia global de 95,66% e um índice kappa de 0,79 – o que enquadra o resultado como desempenho “muito bom”. Isso mostra que, apesar da mudança de dados de entrada, o RF conseguiu manter bom desempenho de classificação quando comparado ao MaxVer.

5.3 CLASSIFICAÇÕES DO *BANDSET 3*

Assim como o *bandset 2*, o *bandset 3* possui 9 bandas, diferenciando-se apenas pela substituição das bandas do radar pelos índices físicos. O mapeamento temático resultante das classificações pode ser visto na figura 31.

Figura 31 - Resultado da classificação do bandset 3 utilizando os classificadores Máxima Verossimilhança e Random Forest



Fonte: O autor, 2021.

O resultado das classificações é semelhante ao *bandset 2* no que diz respeito ao desempenho dos classificadores em termos de mapeamento temático. De fato, a partir da imagem 27, é possível observar a fragmentação da classificação por MaxVer em relação ao *Random Forest*. Os resultados estatísticos dessas classificações são mostrados nas tabelas 9 e 10.

Tabela 9 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 3 por MaxVer

Matriz de erro - Bandset 3 - Maxver					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,051	0,0011	20187900	0,052
	Não mangue	0,2299	0,718	367360200	0,948
	Total	0,2809	0,7191	387548100	
	Área (m ²)	108852122	278695978	387548100	
SE		0,0077	0,0077		
SE área		2990547	2990547		
95% CI area		5861473	5861473		
PA [%]		18,15	99,85		
UA [%]		97,88	75,75		
Kappa hat		0,97	0,14		
Overall accuracy [%] =			76,90		
Kappa hat classification =			0,24		

Fonte: O autor, 2021.

Tabela 10 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do bandset 3 por Random Forest

Matriz de erro - Bandset 3 - Random Forest					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,0815	0,0019	32303700	0,083
	Não mangue	0,0455	0,8711	3,55E+08	0,917
	Total	0,127	0,873	3,88E+08	
	Área (m ²)	49205351	3,38E+08	3,88E+08	
SE		0,0043	0,0043		
SE área		1650446	1650446		
95% CI area		3234874	3234874		
PA [%]		64,16	99,78		
UA [%]		97,74	95,04		
Kappa hat		0,97	0,61		
Overall accuracy [%] =			95,26		
Kappa hat classification =			0,75		

Fonte: O autor, 2021

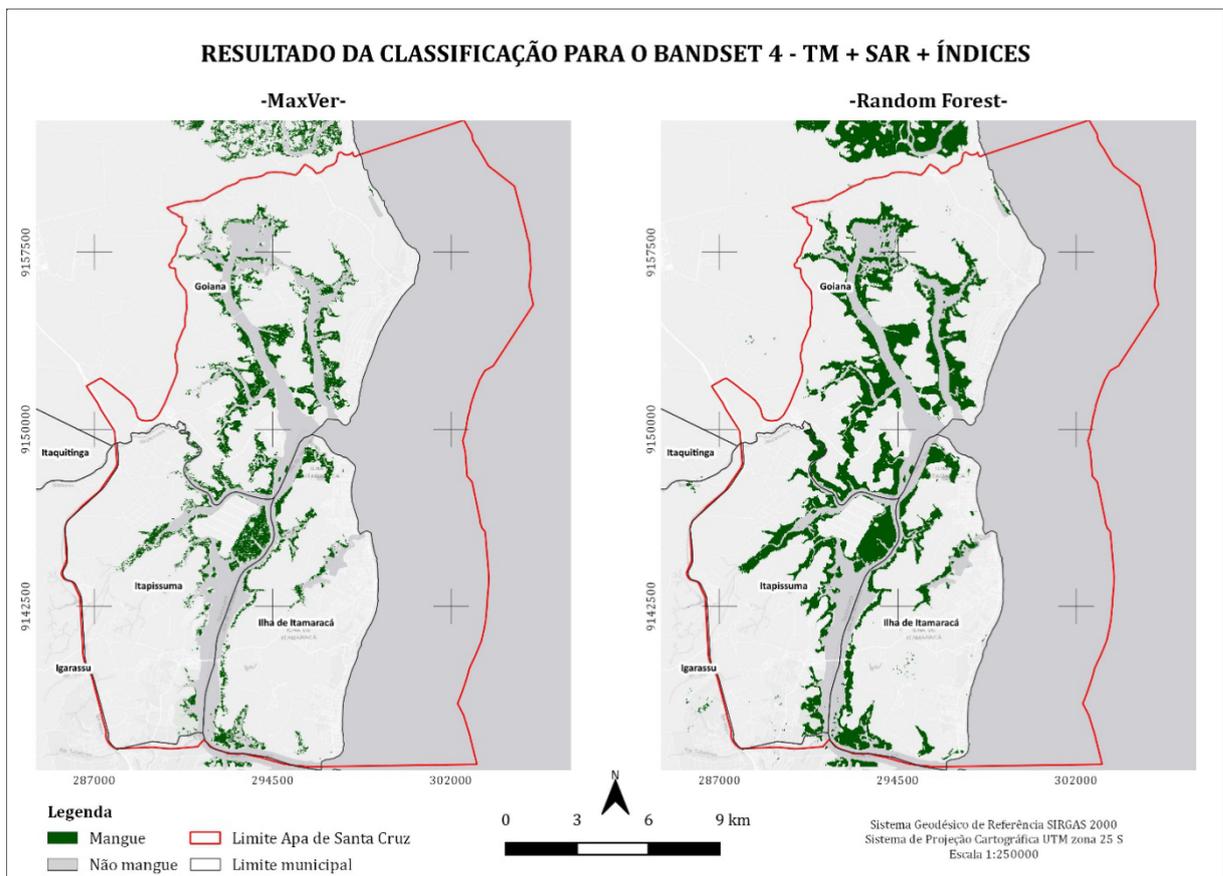
Pode-se observar (tabelas 9 e 10), que os resultados se mostraram semelhantes aos do *bandset 2*. Para o MaxVer, obteve-se uma acurácia global de de 76,90% e índice kappa no valor de 0,23, enquadrando-se, assim como no resultado do item anterior, como uma classificação de desempenho “razoável”. Além disso, possuiu também uma acurácia do produtor baixa para a classe “mangue”, e por fim o valor de área classificada de 2018,79ha. Já

o RF possuiu acurácia global de 95,26%, e índice kappa de 0,75% enquadrando-se como uma classificação de “bom” desempenho. Em relação a área, possuiu uma área classificada total de 3230,37ha, diferindo do MaxVer em 1211,58ha.

5.4 CLASSIFICAÇÕES DO *BANDSET 4*

Por fim, as classificações realizadas com o *bandset 4*, que possui todas as bandas do sensor TM, as bandas ALOS/PALSAR e os índices, tiveram o comportamento semelhante aos dos resultados dos *bandsets* anteriores em termos de mapeamento temático. Os mapas gerados de cada classificação podem ser observados na figura 32.

Figura 32 - Resultado da classificação do *bandset 4* utilizando os classificadores Máxima Verossimilhança e *Random Forest*



Fonte: O autor, 2021.

O mapa da figura 32 mostra grandes fragmentações existentes em relação ao mapeamento temático da classe mangue a partir do classificador MaxVer e consistência do

classificador *Random Forest* com o aumento da quantidade de dados de entrada. As tabelas 11 e 12 mostram a avaliação da acurácia das classificações do *bandset* 4.

Tabela 11 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset* 4 por MaxVer

Matriz de erro - Bandset 4 - Maxver					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,0465	0,001	18389700	0,0475
	Não mangue	0,2534	0,6991	369158400	0,9525
	Total	0,2999	0,7001	387548100	
	Área (m ²)	116224361	271323739	387548100	
SE		0,0079	0,0079		
SE área		3047423	3047423		
95% CI area		5972948	5972948		
PA [%]		15,50	99,86		
UA [%]		97,96	73,40		
Kappa hat		0,97	0,11		
Overall accuracy [%] =			74,56		
Kappa hat classification =			0,20		

Fonte: O autor, 2021.

Tabela 12 - Matriz de erro (baseada em proporção de área) e estatísticas de acurácia da classificação do *bandset* 4 por Random Forest

Matriz de erro - Bandset 4 - Random Forest					
		Referência			
		Mangue	Não Mangue	Área (m ²)	Wi
Classificação	Mangue	0,089	0,002	35156700	0,091
	Não mangue	0,034	0,876	352391400	0,909
	Total	0,122	0,878	387548100	
	Área (m ²)	47393471	340154629	387548100	
SE		0,0037	0,0037		
SE área		1431754	1431754		
95% CI área		2806237	2806237		
PA [%]		72,56	99,77		
UA [%]		97,82	96,31		
Kappa hat		0,98	0,70		
Overall accuracy [%] =			96,45		
Kappa hat classification =			0,81		

Fonte: O autor, 2021.

Deste último *bandset*, as tabelas 11 e 12, mostram os dois extremos de resultados quantitativos para classificações, em que, o MaxVer obteve seu pior resultado e o RF o seu

melhor. Em relação MaxVer, a classificação teve um desempenho de 74,56% e um índice kappa de 0,20 – desempenho próximo ao limiar entre “ruim” e “razoável”- os piores resultados entre todas as classificações. Além disso, a classe mangue possuiu uma acurácia de produtor de 15,50%, a menor em relação a todos os outros resultados.

Já para o RF, os resultados se mostraram os melhores entre as classificações, obtendo desempenhos de classificação de 96,45% de acurácia global e 0,81 de índice kappa, classificando-se, portanto, em uma classificação de desempenho “excelente”.

5.5 RESUMO DOS RESULTADOS ESTATÍSTICOS DAS CLASSIFICAÇÕES

Para uma visualização mais geral em relação aos resultados, a tabela 13 abaixo mostra um resumo das estatísticas de acurácia dos dois classificadores em cada *bandset* em termos de acurácia global, acurácia do produtor e usuário (apenas para a classe “mangue”) e índice kappa.

Tabela 13 - Resumo das principais estatísticas de avaliação de acurácia para as classificações

Bandset	MaxVer				Random Forest			
	AO (%)	PA (%)	UA (%)	k	AO (%)	PA (%)	UA (%)	k
1	95,96	69,20	98,07	0,79	95,76	68,37	98,06	0,78
2	77,62	18,75	97,92	0,25	95,66	69,77	97,80	0,79
3	76,90	18,15	97,88	0,24	95,26	64,16	97,74	0,75
4	74,56	15,50	97,96	0,20	96,45	72,56	97,82	0,81

Fonte: O autor, 2021.

Desta tabela é possível verificar que o MaxVer teve um bom desempenho apenas quando o *bandset 1* foi usado para classificação – o que utilizou apenas bandas da imagem óptica. A inclusão de dados de entrada de fontes diferentes culminou na diminuição da acurácia global, acurácia do produtor e índice kappa para esse classificador. Essa diminuição de desempenho está relacionada com a característica do classificador de assumir que todas as bandas da imagem de entrada tem distribuição normal, e isto não ocorre quando é introduzido dados diferentes, como os dados SAR e os índices físicos.

Em relação a acurácia do produtor, essa diminuição de desempenho significa que houve redução da capacidade do classificador de distinguir e separar as duas classes baseado nas amostras de avaliação. Além disso, nota-se a consistência dos resultados da acurácia do produtor para este mesmo classificador, em torno de 97 a 98%. Indicando que, apesar da

dificuldade do classificador em separar “mangue” de “não mangue”, todos os pixels classificados como mangue tem grande probabilidade de estar em consonância com a verdade terrestre. Uma solução para a melhora dos resultados obtidos por MaxVer nos bandsets 2, 3 e 4, é a utilização de um filtro passa-baixa com a finalidade de diminuir o efeito sal e pimenta existente nas classificações, generalizando o resultado obtido.

Quanto ao *Random Forest*, este manteve uma boa acurácia global em todas as classificações realizadas e obteve seus maiores valores estatísticos quando a quantidade de bandas no bandset foi a maior (*bandset 4*), o que mostra que a introdução de outros dados de entrada ajudou a classificação. Isso pode ser observado mais especificamente em relação a acurácia do produtor que teve valor de 72,56%, mostrando que de todas as 8 classificações existentes, o RF utilizando todos os dados de entrada (*bandset 4*) proporcionou a melhor separabilidade das classes mangue e “não mangue”.

Para a análise em relação as áreas, a tabela 14 mostra um resumo das áreas classificadas calculadas para cada algoritmo e a diferença existente elas.

Tabela 14 – Diferença entre as áreas classificadas como mangue em cada bandset

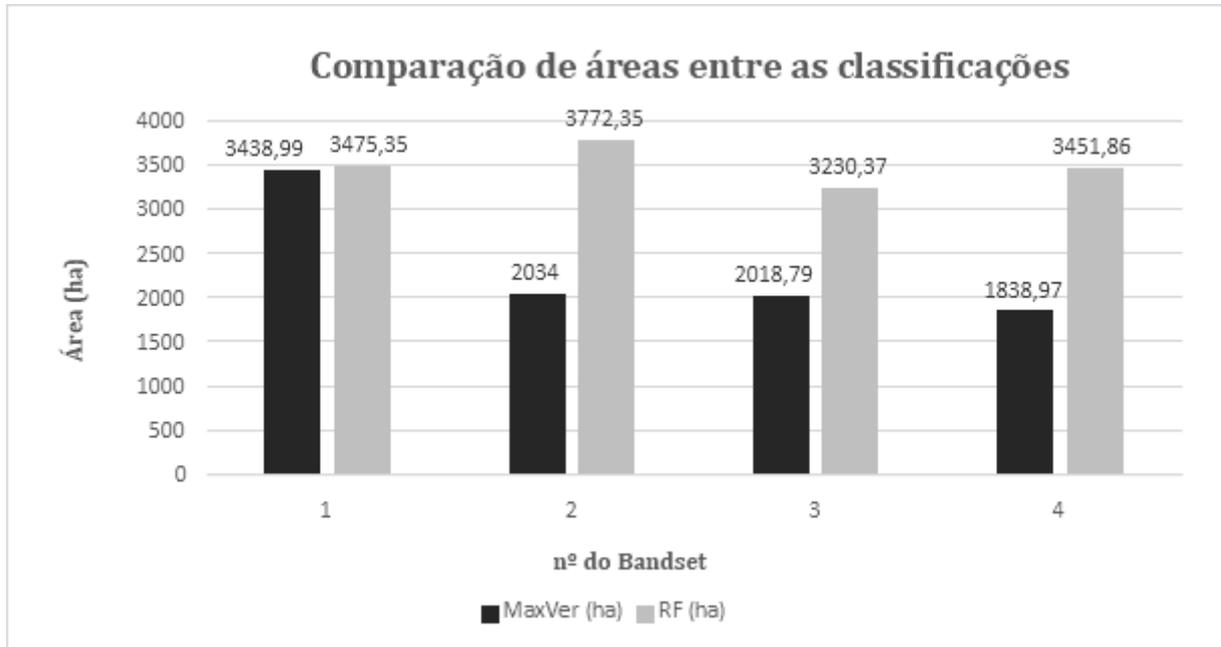
Bandset	MaxVer (ha)	RF (ha)	(RF - MaxVer) (ha)
1	3438,99	3475,35	36,36
2	2034,00	3772,35	1738,35
3	2018,79	3230,37	1211,58
4	1838,97	3451,86	1612,89

Fonte: O autor, 2021.

Essa tabela revela as discrepâncias que existem no cômputo da área de cada classificação. Isso é um problema cartográfico bastante relevante, pois apesar da utilização dos mesmos dados de entrada, foram geradas classificações temáticas diferentes e, conseqüentemente, cálculo de áreas diferentes. Um exemplo disto é que, o resultado com maior área de mangue classificado foi o da classificação do *bandset 2* por *Random Forest* (3772,35 ha), enquanto a menor foi a classificação do *bandset 4* por MaxVer (1838,97 ha), resultando numa diferença de 1933,38 ha em área classificadas. Além disso, o valor das áreas se tornaram mais próximos quando o MaxVer obteve o seu melhor desempenho, resultando numa diferença de 36,36 ha.

Para melhor visualização destes aspectos esta comparação também pode ser feita através de gráficos (figura 33).

Figura 33 - Gráfico da comparação entre as áreas geradas pela classificação dos *bandsets* por Máxima Verossimilhança e *Random Forest*



Fonte: O autor, 2021.

Essa figura exibe as diferenças entre áreas de forma visual, mostrando que no *bandset* 1 existiu uma melhor equivalência entre os classificadores em termos de área classificada. É possível visualizar também que, com a introdução de outras informações de entrada, a área classificada como mangue por MaxVer foi diminuindo e, conseqüentemente, a discrepância entre o valor de área computado foi maior.

A comparação das classificações com os dados do Mapbiomas foi realizada apenas em relação a área de classificação. Como abordado na seção 4.2, a área calculada de mangue a partir do Mapbiomas na APA de Santa Cruz para o ano de 2010 foi de 3476,35ha. Desta forma a tabela 17, mostra as diferenças em área entre as classificações e o dado de referência, assim como o erro percentual absoluto.

Tabela 15 - Diferença entre as áreas calculadas e a área da classe mangue do Mapbiomas (2010)

Bandset	d_MaxVer (ha)	d_MaxVer (%)	d_RF (ha)	d_RF (%)
1	-37,36	1,07	-1,00	0,03
2	-1442,35	41,49	296,00	8,51
3	-1457,56	41,93	-245,98	7,08
4	-1637,38	47,10	-24,49	0,70

Fonte: O autor, 2021.

Como visto na tabela 15, os resultados que mais se aproximaram da área computada pelo Mapbiomas foram a classificação do *bandset* 1 por MaxVer e RF (1,07% e 0,03% de erro, respectivamente) e a classificação do *bandset* 4 por RF (erro de 0,70%). Este tipo de avaliação em relação ao outro dado de referência é importante para se saber a proximidade da classificação em termos de área de mapeamento temático.

Um fato interessante é que o Mapbiomas utiliza o RF como classificador superviosinado para classificação de 27 (vinte e sete) classes de uso e cobertura do solo. Para realizar esta classificação tão robusta, utiliza 104 (cento e quatro) variáveis de entrada, dentre elas bandas multiespectrais, índices físicos e informações texturais e fracionadas destas bandas. Porém, as classificações resultantes do *bandset* 1 (principalmente por RF), mostra que para a diferenciação da classe mangue apenas com bandas do sensor óptico é suficiente para atingir um resultado (em termos de área) próximo ao do Mapbiomas. Além do 1, a classificação do *bandset* 3 por RF apresenta valores de área próximos ao do Mapbiomas com a utilização de todas as bandas (TM+SAR+ÍNDICES) e com uma acurácia global um pouco melhor (96,45%).

Por fim, uma característica importante das classificações por *Random Forest* é o ranking de importância das variáveis por classificação. O quadro 7, a seguir, mostra as 5 bandas com maior importância para separação entre as classes e, portanto, maior importância na classificação. Essas informações são disponibilizadas pelo SCP logo após que a classificação é realizada.

Quadro 7 - Ranking de relevância das variáveis na classificação por Random Forest

Ranking	Bandset 1	Descrição 1	Bandset 2	Descrição 2	Bandset 3	Descrição 3	Bandset 4	Descrição 4
1º lugar	Banda 5	TM 5 (SWIR 1)	Banda 5	TM 5 (SWIR 1)	Banda 8	ÍNDICE (NDWI)	Banda 11	ÍNDICE (NDWI)
2º lugar	Banda 3	TM 3 (RED)	Banda 4	TM 4 (NIR)	Banda 9	ÍNDICE (SAVI)	Banda 5	TM 5 (SWIR 1)
3º lugar	Banda 4	TM 4 (NIR)	Banda 6	TM 7 (SWIR 2)	Banda 7	ÍNDICE (NDVI)	Banda 12	ÍNDICE (SAVI)
4º lugar	Banda 2	TM 2 (GREEN)	Banda 8	PALSAR (HV)	Banda 5	TM 5 (SWIR 1)	Banda 4	TM 4 (NIR)
5º lugar	Banda 6	TM 7 (SWIR 2)	Banda 7	PALSAR (HH)	Banda 6	TM 7 (SWIR 2)	Banda 10	ÍNDICE (NDVI)

Fonte: O autor, 2021.

Deste quadro é possível verificar que as variáveis que aparecem em 1º lugar no ranking de importância são a banda 5 do sensor TM (SWIR 1) e o índice de vegetação NDWI. Como o NDWI utiliza em seu cálculo a banda do SWIR 1, pode-se dizer que esta banda teve maior relevância num contexto global. Isto é de se esperar pois esta banda é sensível ao conteúdo de água presente na vegetação e como o mangue tem a característica de estar sob frequentes inundações, a banda do SWIR 1, assim como o NDWI demonstram bom desempenho na classificação desse alvo. Pode-se notar também que os índices físicos, quando presentes nos bandsets, sempre aparecem entre as 5 bandas de maior importância, o que indica a relevância desses índices para a diferenciação de tipos de vegetação e de vegetação com outros alvos.

Além disso, é interessante notar que como não houve (neste caso específico) boa separabilidade entre as classes na imagem de radar, as bandas do ALOS/PALSAR aparecem só ranking da classificação do *bandset 2*. Isso pode ser visto na figura 17 (seção 4.3.2), onde é possível observar que não existe, de modo visual, diferenciação entre a vegetação de mangue e a vegetação de mata atlântica adjacente. Isso pode estar relacionado com as dificuldades apontadas por Lucas et al. (2007), em que a resposta da banda-L de manguezais pode ser semelhante a das vegetações adjacentes e, sabendo que a maré não estava alta no horário da aquisição da imagem, o mangue não estava inundado.

6 CONSIDERAÇÕES FINAIS

A APA de Santa Cruz é uma região que necessita de monitoramento, devido a sua importância socioambiental, para assim promover a proteção dos recursos hídricos, aquíferos, espécies raras e endêmicas que são encontradas na região, além de preservar a cultura e hábitos das comunidades tradicionais. A região conta com um importante acervo histórico cultural para o estado de Pernambuco, além de sua relevância para a manutenção da biodiversidade marinho-estuarina.

Neste trabalho, verificou-se a importância da avaliação da acurácia de uma classificação como forma de comparação entre o desempenho de classificadores com características diferentes. Em relação aos resultados obtidos, as métricas de avaliação de acurácia mostram que os dois classificadores têm bom desempenho quando utilizadas apenas bandas de imagens ópticas na classificação. Isso se dá, como já foi explanado, pela modelagem do classificador MaxVer da distribuição de probabilidade das classes amostradas na imagem. Entretanto, quando mudados os dados de entradas para *bandsets* com informações de fontes diferentes, nota-se que o *Random Forest* se torna mais robusto, mantendo uma boa acurácia global em todas as classificações. Além disso, a melhor acurácia global, do produtor e melhor índice kappa obtido neste estudo foi quando se utilizou todas as bandas disponíveis na classificação por esse algoritmo.

Portanto, a classificação de mangues com qualquer um desses dois algoritmos a partir de imagens ópticas (*bandset* 1) já seria suficientemente aceitável, dados os resultados de acurácia obtidos. Porém, percebe-se que o critério que deverá ser observado na escolha entre um deles é o tipo de dado a ser utilizado na classificação; se os dados não possuem distribuição gaussiana é recomenda-se a utilização de classificadores mais robustos como o *Random Forest*.

Entretanto, como este trabalho se propões apenas a separar as macroclasses “mangue” e “não mangue”, é possível que haja mudanças em relação a acurácia das classificações se ela fosse realizada com a estratificação da macroclasse “não mangue”, como área urbana, solo exposto, vegetação, entre outros. Além disso, é necessário ressaltar que os resultados estão relacionados também com a quantidade e a informação contida nos dados de entrada. A utilização de outros índices, até mais específicos para a detecção de mangues - como os propostos por Winarso et al. (2014), e Baloloy et al. (2020) - podem gerar resultados melhores tanto em relação a acurácia do produtor quando na acurácia global.

É importante salientar também que houve problemas de separabilidade de classes quando observada a imagem de radar. A diferenciação tornou-se difícil devido a confusão existente entre o mangue e a mata atlântica adjacente, onde percebe-se visualmente que essas duas classes tiveram respostas semelhantes. Uma das prováveis possibilidades para isso é que o mangue não estava alagado na hora da aquisição da imagem, devido a maré baixa, o que proporcionou essa confusão. Entretanto, apesar dessa não separabilidade, o *Random Forest* conseguiu ainda classificar bem os *bandsets* que continham estas bandas, o que confirma ainda mais a robustez desse classificador.

Além disso, uma vantagem referente a utilização do *Random Forest* é a indicação do ranking de importância das variáveis para classificação, o que pode fornecer ao analista as melhores bandas para a separabilidade de determinadas classes. Para este estudo, essa característica do *Random Forest*, mostrou que a banda referente ao SWIR 1 (banda 5 do sensor TM) tem uma grande relevância no que se refere a classificação de mangues, além disso, os índices físicos NDWI, SAVI e NDVI sempre apareceram entre as 5 bandas mais relevantes quando existentes no *bandset* de classificação.

É importante também ressaltar o potencial do uso de softwares livres para o processamento de imagens, mais especificamente em relação ao *Semi-Automatic Classification Plugin*. Este plugin, utilizado em consonância com as ferramentas de geoprocessamento se torna uma poderosa plataforma de análise de imagens de Sensoriamento Remoto. É necessário também destacar que este plugin, diferentemente de outros disponíveis para download, apresenta documentação acessível, o que permite a confiabilidade dos métodos utilizados. Apesar disso, em relação ao *Random Forest*, o plugin necessita da utilização de um software externo para poder executar esse tipo de classificação.

REFERÊNCIAS

- ABDEL-HAMID, Ayman; DUBOVYK, Olena; ABOU EL-MAGD, Islam; MENZ, Gunter. Integration of SAR and Optical Remote Sensing data for mapping of mangroves extents. *In: OTJACQUES, Benoît; HITZELBERGER, Patrik; NAUMANN, Stefan; WOHLGEMUTH, Volker (Eds.). Science to Society: The Bridge provided by Environmental Informatics Adjunct Proceedings of the 31st EnviroInfo conference.* Luxemburgo, 2017.
- ALASKA SATELLITE FACILITIES - ASF DAAC 2014. **ALOS PALSAR Radiometric Terrain Corrected low res.** Includes Material © JAXA/METI 2020. Disponível em: <https://asf.alaska.edu>. Acesso em: 15 fev. 2021.
- ANDRADE, Alexandre Curvelo; FRANCISCO, Cristiane Nunes; ALMEIDA, Cláudia Maria. Desempenho de classificadores paramétrico e não paramétrico na classificação da fisionomia vegetal. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 66, n. 2, p. 349-363, jan./abr. 2014. Disponível em: <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43917/23181>. Acesso em: 9 fev. 2021.
- ARAÚJO, Carlos Alberto Sampaio de. **Aplicações de técnicas de Sensoriamento Remoto na análise multitemporal do ecossistema manguezal na Baixada Santista, SP.** Orientador: Dr. Luis Américo Conti. 2010. 113 f. Dissertação (Mestrado em Oceanografia Química e Geológica), Universidade de São Paulo, São Paulo, 2010. Disponível em: <https://www.teses.usp.br/teses/disponiveis/21/21133/tde-02082011-110739/pt-br.php> . Acesso em: 12 mar. 2021.
- ASCHBACHER, Josef; OFREN, Rey; DELSOL, Jean Pierre; SUSELO, Tri Binarko et al. An integrated comparative approach to mangrove vegetation mapping using advanced remote sensing and GIS technologies: Preliminary results. **Hydrologica**, v. 295, p. 285-295, jan. 1995. Disponível em: <https://link.springer.com/article/10.1007/BF00029135>. Acesso em: 15 fev. 2021.
- BALOLOY, Alvin B.; BLANCO, Ariel C.; STA. ANA, Raymund Rhommel C.; NADAOKA, Kazuo. Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 166, p. 95–117, ago. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271620301519>. Acesso em: 20 v. 2021.
- BANKO, Gebhard. **A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data and of Methods Including Remote Sensing Data in Forest Inventory.** Luxemburgo: IIASA, 1998. 36 p.
- BELGIU, Mariana; DRĂGUȚ, Lucian. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 114, p. 24–31, 2016. Disponível em: <https://ui.adsabs.harvard.edu/abs/2016JPRS..114...24B/abstract>. Acesso em: 16 fev. 2021.

BLASCO, F.; GAUQUELIN, T.; RASOLOFOHARINORO, M.; DENIS, J.; AIZPURU, M.; CALDAIROU, V. Recent advances in mangrove studies using remote sensing data. **Marine and Freshwater Research**, v. 49, p. 287-296, 1998. Disponível em:

<https://www.semanticscholar.org/paper/RECENT-ADVANCES-IN-MANGROVE-STUDIES-USING-REMOTE-Blasco-Gauquelin/91573648d75b62a4e594dc6d293c562eb711a0>. Acesso em: 20 fev. 2021.

BOULESTEIX, Anne-Laure; JANITZA, Silke; KRUPPA, Jochen; KÖNIG, Inke R. Overview of random forest methodology and practical guidance with emphasis on computational biology and bioinformatics. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 2, n. 6, p. 493–507, out. 2012. Disponível em:

<https://onlinelibrary.wiley.com/doi/abs/10.1002/widm.1072>. Acesso em: 03 mar. 2021.

BISHOP, Yvonne M.; FIENBERG, Stephen E.; HOLLAND, Paul W. **Discrete Multivariate Analysis: Theory and Practice**. Cambridge: MIT Press, 2007, 575 p.

BREIMAN, Leo. Random Forests. **Machine Learning**, v. 45, p. 5–32, 2001. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acesso em: 25 mar. 2021.

CARVALHO, Marcus Vinícius Alves de; SILVA, Gabriella Ferreira da; CRUZ, Carla Bernadete Madureira; ALMEIDA, Paula Maria Moura de. Avaliação do mapeamento de manguezais na Região Metropolitana do Rio de Janeiro através da integração entre GEOBIA e Mineração de Dados. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 17., 2015, João Pessoa. **Anais eletrônicos...** São José dos Campos: INPE, 2015. p. 3580-3587. Disponível em: <http://urlib.net/rep/8JMKD3MGP6W34M/3JM4BRK>. Acesso em: 9 mar. 2021.

CEARÁ (Estado). Governo do Estado do Ceará. **Atlas dos Manguezais do Nordeste do Brasil: avaliação das áreas de manguezais dos Estados do Piauí, Ceará, Rio Grande do Norte, Paraíba e Pernambuco**. Fortaleza: SEMACE, 2006.

CENTENO, Jorge Antônio Silva. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: UFPR, 2004. 209 p.

COHEN, Jacob. A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, abr. 1960. Disponível em: <https://journals.sagepub.com/doi/10.1177/001316446002000104>. Acesso em: 15 fev. 2021.

CONGALTON, Russell G. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, Brandon, v. 10, p. 321-328, 2001. Disponível em:

https://www.researchgate.net/publication/220040678_Accuracy_assessment_and_validation_of_remotely_sensed_and_other_spatial_information. Acesso em: 16 fev. 2021.

CONGALTON, Russell G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, Amsterdã, v. 37, n. 1, p. 35–46, jul. 1991. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/003442579190048B>. Acesso em: 16 fev. 2021.

CONGALTON, Russell G.; GREEN, Kass. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 3. ed. Boca Raton: CRC Press, 2019. 346 p.

CONGEDO, Luca. **Semi-Automatic Classification Plugin Documentation**. 2020. Disponível em: <http://dx.doi.org/10.13140/RG.2.2.25480.65286/1>. Acesso em: 02 mar. 2021.

COUTINHO, Sonia Maria Viggiani.; SULAIMAN, Samia Nascimento; CARBONE, Amanda Silveira. **Área de Proteção Ambiental (APA) de Santa Cruz: (re)conhecendo o valor ecológico, histórico-cultural e econômico**. Recife: CPRH, 2018. 48p.

CRÓSTA, Alvaro Penteadó. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1992. 170 p.

CUNHA-LIGNON, Marília; KAMPEL, Milton. Análise multitemporal de imagens Landsat para monitoramento de áreas de manguezal: subsídio à gestão costeira do litoral sul do Estado de São Paulo. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais eletrônicos...** São José dos Campos: INPE, 2011. p. 5032-5038. Disponível em: <http://urlib.net/rep/3ERPFQRTRW/3A3AP2P>. Acesso em: 02 fev. 2021.

DAHDOUH-GUEBAS, Farid. The use of remote sensing and GIS in the sustainable management of tropical coastal ecosystems. **Environment, Development and Sustainability**, v. 4, n. 2, p. 93-112, Jan. 2002. Disponível em: https://www.researchgate.net/publication/226519231_The_Use_of_Remote_Sensing_and_GIS_in_the_Sustainable_Management_of_Tropical_Coastal_Ecosystems. Acesso em: 20 mar. 2021.

FONSECA, Leila Maria Garcia. **Processamento digital de imagens**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

FOODY, Giles M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, Amsterdã, v. 80, n. 1, p. 185–201, abr. 2002. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425701002954>. Acesso em: 15 fev. 2021.

FUNDAÇÃO APOLÔNIO SALLES DE DESENVOLVIMENTO EDUCACIONAL; AGÊNCIA AMBIENTAL DE MEIO AMBIENTE. **Diagnóstico da Área de Proteção Ambiental - APA Santa Cruz – Itapissuma, Itamaracá e Goiana, PE**. Recife: FADURPE/CPRH, 2010a. Disponível em: http://www.cprh.pe.gov.br/ARQUIVOS_ANEXO/diagnosticosantacruz;2243;20120906.pdf. Acesso em: 05 fev. 2021.

FUNDAÇÃO APOLÔNIO SALLES DE DESENVOLVIMENTO EDUCACIONAL; AGÊNCIA AMBIENTAL DE MEIO AMBIENTE. **Zoneamento Ambiental da Área de Proteção Ambiental - APA Santa Cruz – Itapissuma, Itamaracá e Goiana, PE**. Recife: FADURPE/CPRH, 2010b. Disponível em: <http://www2.cprh.pe.gov.br/wp-content/uploads/2021/01/zoneamentosantacruz.pdf>. Acesso em: 05 fev. 2021.

GAO, Bo-cai. NDWI- a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, Amsterdã, v. 58, n. 3, p. 257-266, dez. 1996. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0034425796000673#:~:text=In%20this%20article%2C%20another%20index,vegetation%20liquid%20water%20from%20space.&text=Absorption%20by%20vegetation%20liquid%20water,scattering%20enhances%20the%20water%20absorption.> Acesso em: 02 mar. 2021.

GEOLOGICAL SURVEY EARTH RESOURCES OBSERVATION AND SCIENCE CENTER. **Landsat Science Products courtesy of the U.S.**

GIRI, Chandra; OCHIENG E.; TIESZEN, L. L.; ZHU, Z.; SINGH, A.; LOVELAND, T.; MASEK, J.; DUKE, N. Status and distribution of mangrove forests of the world using earth observation satellite data. **Global Ecology and Biogeography**, v. 20, n. 1, p. 154–159, jan. 2011. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1466-8238.2010.00584.x>. Acesso em: 11 fev. 2021.

GREEN, E. P.; CLARK, C. D.; MUMBY, P. J.; EDWARDS, A. J.; ELLIS, A. C. Remote sensing techniques for mangrove mapping. **International Journal of Remote Sensing**, v. 19, n. 5, p. 935–956, 1998. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/014311698215801>. Acesso em: 17 fev. 2021.

HEUMANN, Benjamin W. Satellite remote sensing of mangrove forests: recent advances and future opportunities. **Progress Physical Geography**, v. 35, n. 1, p. 87–108, 2011. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/0309133310385371>. Acesso em: 5 fev. 2021.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, Amsterdã, v. 25, n. 3, p. 295–309, ago. 1988. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/003442578890106X>. Acesso em: 20 fev. 2021.

ICMbio. **Atlas dos Manguezais do Brasil**. Brasília: Instituto Chico Mendes de Conservação da Biodiversidade, 2018. 176 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Manuais: tutorial de geoprocessamento SPRING**. São José dos Campos: INPE, 2008.

JENSEN, John R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Pearson Prent Hall, 2009. 598p.

JHONNERIE, Romie; SIREGAR, Vincentius P.; NABABAN, Bisman; PRASETYO, Lilik. B.; WOUTHUYZEN, Sam; Random Forest Classification for Mangrove Land Cover Mapping Using Landsat 5 TM and Alos Palsar Imageries. **Procedia Environmental Sciences**, Amsterdã, v. 24, p. 215-221, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1878029615000961?via%3Dihub>. Acesso em: 12 mar. 2021.

JIANG, Zhangyan; HUETE, Alfredo R.; CHEN, Jin; CHEN, Yunhao et al. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. **Remote Sensing of Environment**, v. 101, n. 3, p. 366-378, abr. 2006. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425706000290>.

Acesso em: 20 fev. 2021.

KRUG, Lilian Anne.; LEÃO, Caroline; AMARAL, Silvana. Dinâmica espaço temporal de manguezais no Complexo Estuarino de Paranaguá e relação entre decréscimo de áreas de manguezal e dados sócio-econômicos da região urbana do município de Paranaguá – Paraná. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 13., 2007, Florianópolis. **Anais eletrônicos...** São José dos Campos: INPE, 2017.p. 2753-2760. Disponível em: <http://marte.sid.inpe.br/rep/dpi.inpe.br/sbsr@80/2006/11.14.20.50?mirror=dpi.inpe.br/banon/2003/12.10.19.30.54&metadatarepository=dpi.inpe.br/sbsr@80/2006/11.14.20.50.21>. Acesso em: 02 fev. 2021.

KUENZER, Cláudia; BLUEMEL, Andrea; GEBHARDT, Steffen; QUOC, Tuan Vo; DECH, Stefan. Remote Sensing of Mangrove Ecosystems: A Review. **Remote Sensing**, v. 3, n. 5, p. 878-928, abr. 2011. Disponível em: <https://www.mdpi.com/2072-4292/3/5/878>. Acesso em: 05 fev. 2021.

KULKARNI, Arun D.; LOWE, Barrett. Random Forest Algorithm for Land Cover Classification. *Computer Science Faculty Publications and Presentations*, v. 4, n. 3, p. 58-63, mar. 2016. Disponível em: <http://hdl.handle.net/10950/341>. Acesso em: 02 fev. 2021.

LILLESAND, Thomas M.; KIEFER, Ralph W.; CHIPMAN, Jonathan W. **Remote Sensing and Image Interpretation**. 7. ed. New York: Wiley, 2015. 736 p.

LUCAS, Richard M.; BUNTING, Pete J.; CLEWLEY, Daniel; PROISY, Christophe et al. Characterisation and Monitoring of Mangroves Using ALOS PALSAR Data; **The ALOS Kyoto & Carbon Initiative Science Team Reports Phase 1 (2006–2008)**, v. 1, p. 158-169, JAXA: Ibaraki, Japan, 2009.

LUCAS, Richard M.; MITCHELL, Anthea L.; ROSENQVIST, Ake; PROISY, Christophe et al. The potential of L-band SAR for quantifying mangrove characteristics and change: case studies from the tropics. **Aquatic Conservation: Marine and Freshwater Ecosystems**, v. 17, n. 3, p. 245–264, 2007. Disponível em: http://amapmed.free.fr/AMAPMED_fichiers/Publications_fichiers/Lucas07.pdf. Acesso em: 9 fev. 2021.

MAPBIOMAS. **O projeto**, c2021. Conheça o Mapbiomas. Disponível em: <https://mapbiomas.org/o-projeto>. Acesso em: 25 mar. 2021.

MASEK, Jeffrey G.; VERMOTE, Eric F.; SALEOUS, Nazmi E.; WOLFE, Robert et al. A Landsat surface reflectance dataset for North America, 1990–2000. **IEEE Geoscience and Remote Sensing Letters**, Piscataway, v. 3, n. 1, p. 68-72, jan. 2006. Disponível em: <https://ieeexplore.ieee.org/document/1576692>. Acesso em: 05 mar. 2021.

MENESES, Paulo Roberto; ALMEIDA, Tati de. **Introdução ao processamento de imagens de Sensoriamento Remoto**. 1. ed. Brasília: Conselho Nacional de Desenvolvimento Científico e Tecnológico, 2012. 266 p.

MENESES, Paulo Roberto; ALMEIDA, Tati de; BAPTISTA, Gustavo Macedo de Mello. **Reflectância dos materiais terrestres – análise e interpretação**. São Paulo: Oficina de textos, 2019. 336 p.

MEYER, Franz. Spaceborn Synthetic Aperture Radar: principles data access and basic process techniques. In: FLORES-ANDERSON, Africa I.; HERNDON, Kelsey E.; THAPA, Rajesh B.; CHERRINGTON, Emil. **The SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation**. Huntsville: National Space Science and Technology Center, 2019, p. 21-64

MONICO, João Francisco Galera et al. Acurácia e precisão: revendo os conceitos de forma acurada. **Boletim de Ciências Geodésicas**, Curitiba, v. 15, n. 3, p. 469-483, jul./set. 2009. Disponível em: <https://revistas.ufpr.br/bcg/article/view/15513/10363>. Acesso em: 9 fev. 2021.

NOVO, Evlyn Marcia Leão de Moraes. **Sensoriamento Remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2010. 378 p.

OLOFSSON, Pontus; GILES, M. Foody; HEROLD, Martin; STEHMAN, Stephen V. et al. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, Amsterdã, v. 148, p. 42-57, mai. 2014. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425714000704>. Acesso em: 02 fev. 2021.

OLOFSSON, Pontus; GILES, M. Foody; STEHMAN, Stephen V.; WOODCOCK, Curtis E. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. **Remote Sensing of Environment**, Amsterdã, v. 129, pp. 122–131, fev. 2013. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425712004191>. Acesso em: 02 fev. 2021.

PEREIRA, Francisca Rocha de Souza; KAMPEL, Milton; CUNHA-LIGNON, Marília. Detecção de bosques de mangue em imagens de Radar de Abertura Sintética (SAR) utilizando classificador contextual baseado na frequência. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais eletrônicos...** São José dos Campos: INPE, 2011. p. 8177-8184. Disponível em: <http://urlib.net/rep/3ERPFQRTRW/3A3PMSE>. Acesso em: 02 fev. 2021.

PEREIRA, Francisca Rocha de Souza. **Utilização de radar de abertura sintética no estudo da tipologia e da estrutura de bosques de mangue no litoral Sul de São Paulo, Brasil**. Orientador: Dr. Milton Kampel; Dra. Marília Cunha Lignon. 2011. 111 f. Dissertação (Mestrado em Sensoriamento Remoto), Instituto de Pesquisas Espaciais, São José dos Campos, 2011. Disponível em: <http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19/2011/07.13.16.47/doc/publicacao.pdf>. Acesso em: 12 mar. 2021.

PERNAMBUCO (Estado). **Decreto Estadual n 32.488, de 17 de outubro de 2008**. Declara como Área de Proteção Ambiental – APA a região que compreende os Municípios de Itamaracá e Itapissuma e parte do Município de Goiana, e dá outras providências. Disponível em: http://www2.cprh.pe.gov.br/wp-content/uploads/2021/01/decreto_32488.pdf. Acesso em: 25 mar. 2021.

PERNAMBUCO (Estado). **Lei nº 13.539, de 12 de setembro de 2008**. Dispõe sobre a mudança de categoria de Manejo das Reservas Ecológicas da Mata de Santa Cruz e outras. Disponível em: https://www.normasbrasil.com.br/norma/lei-13539-2008-pe_149281.html. Acesso em: 25 mar. 2021.

PERNAMBUCO (Estado). **Lei nº 9.931, de 11 de dezembro de 1986**. Define como área de proteção ambiental as reservas biológicas constituídas pelas áreas estuarinas do Estado de Pernambuco. Disponível em: <http://legis.alepe.pe.gov.br/texto.aspx?id=4853&tipo=TEXTOATUALIZADO#:~:text=LEI%20N%C2%BA%209.931%2C%20DE%2011,estuarinas%20do%20Estado%20de%20Pernambuco>. Acesso em: 25 mar. 2021.

PERROCA, Márcia Galan; GAIDZINSKI, Raquel Rapone. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes - coeficiente Kappa. **Revista da Escola de Enfermagem da USP**, São Paulo, v. 37, n. 1, p. 72-80, 2003. Disponível em: <<http://www.scielo.br/pdf/reeusp/v37n1/09.pdf>>. Acesso em: 9 fev. 2021.

PINHO, Carolina Moutinho Duque de. **Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intraurbano: o caso de São José dos Campos**. 2005. 180 f. Dissertação (Mestrado em Sensoriamento Remoto). INPE - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

PONTIUS, Robert Gilmore; MILLONES, Marco. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, ago. 2011. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01431161.2011.552923>. Acesso em: 02 fev. 2021.

PONZONI, Flávio Jorge; SHIMABUKURO, Yosio Ademir; KUPLICH, Tatiana Mora. **Sensoriamento remoto da vegetação**. São Paulo: Oficina de Textos, 2012. 160 p.

PURNAMASAYANGSUKASIH, Parman Rhyma; NORIZAH, Kamarudin; ISMAIL, Adnan A. M.; SHAMSUDIN, Ibrahim. A review of uses of satellite imagery in monitoring mangrove forests. **IOP conference series: Earth and Environmental Science**, v. 37, 8th IGRSM International Conference and Exhibition on Geospatial & Remote Sensing, Kuala Lumpur, 2016.

RIBEIRO, Bárbara Maria Giacom; FONSECA, Leila Maria Garcia. Urban Land Cover Classification using WorldView-2 Images and C4.5 Algorithm. *In*: PROCEEDINGS OF THE JOINT URBAN REMOTE SENSING SYMPOSIUM, 2013, São Paulo. **Anais eletrônicos...Piscataway**: IEEE, 2013, p. 250-253. Disponível em: <https://ieeexplore.ieee.org/document/6550712>. Acesso em: 02 fev. 2021.

RICHARDS, John A.; JIA, Xiuping. **Remote Sensing Digital Image Analysis: an introduction**. 4. ed. Berlin: Springer, 2006. 439 p.

RICHARDS, J. A.; WOODGATE, P. W.; SKIDMORE, A. K.; An explanation of enhanced radar backscattering from flooded forests. **International Journal of Remote Sensing**, v. 8, n. 7, p. 1093- 1100, abr. 1987. Disponível em:

<https://research.utwente.nl/en/publications/an-explanation-of-enhanced-radar-backscattering-from-flooded-fore>. Acesso em: 16 fev. 2021.

RHYMA P.P.; NORIZAH K.; HAMDAN O.; FARIDAH-HANUM I.; ZULFA A.W.. Integration of normalised different vegetation index and Soil-Adjusted Vegetation Index for mangrove vegetation delineation. **Remote Sensing Applications: Society and Environment**, v. 17, jan. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2352938519301661>. Acesso em: 15 mar. 2021.

RODRIGUEZ-GALIANO V.F.; GHIMIRE, B.; ROGAN J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 67, p. 93-104, jan. 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271611001304>. Acesso em: 02 fev. 2021.

ROSSI, Macio; MATTOS, Isabel Fernandes de Aguiar. O ecossistema mangue – uma análise dos solos e da vegetação no estado de São Paulo. *In*: CONGRESSO NACIONAL SOBRE ESSÊNCIAS NATIVAS, 2., 1992, São Paulo, **Anais eletrônicos...**São Paulo: Instituto Florestal, 1992. p. 930-936. Disponível em: https://smastr16.blob.core.windows.net/iflorestal/ifref/RIF4-3/RIF4-3_930-936.pdf. Acesso em: 02 fev. 2021.

ROUSE, J.W.; R.H. HAAS; J.A. Schell; D.W. DEERING. Monitoring vegetation systems in the Great Plains with ERTS. *In*: S.C. Freden, E.P. Mercanti, and M. Becker (eds). **Third Earth Resources Technology Satellite–1 Symposium**. Volume I: Technical Presentations, NASA SP-351, Washington: NASA, 1974, p. 309-317.

RUSSELL, Stuart; NORVIG, Peter. **Artificial intelligence: a modern approach**. 3. ed. New Jersey: Prentice Hall, 2009. 1132 p.

SANO, Edson Eyji et al. Reflectância da Vegetação. *In*: MENESES, Paulo Roberto; ALMEIDA, Tati de; BAPTISTA, Gustavo Macedo de Mello. **Reflectância dos materiais terrestres – análise e interpretação**. São Paulo: Oficina de textos, 2019. 336 p.

SCHAEFFER-NOVELLI, Yara. Manguezal: ecossistema que ultrapassa suas próprias fronteiras. *In*: CONGRESSO NACIONAL DE BOTÂNICA, 53., 2002, Recife. **Anais...**p. 34-37. 2002.

SCHAEFFER-NOVELLI, Yara. Mangue e manguezal. *In*: Instituto Chico Mendes de Conservação da Biodiversidade - ICMBio (Ed.). **Atlas dos manguezais do Brasil**. Brasília: Instituto Chico Mendes de Conservação da Biodiversidade- ICMBio, 2018a, p. 17-21.

SCHAEFFER-NOVELLI, Yara. A diversidade do ecossistema manguezal. *In*: Instituto Chico Mendes de Conservação da Biodiversidade - ICMBio (Ed.). **Atlas dos manguezais do Brasil**. Brasília: Instituto Chico Mendes de Conservação da Biodiversidade- ICMBio, 2018b, p. 21-35.

SCHAEFFER-NOVELLI, Yara; VALE, CC.; CINTRÓN, G. Monitoramento do ecossistema manguezal: estrutura e características funcionais. *In*: TURRA, A.; DENADAI, MR., orgs. **Protocolos para o monitoramento de habitats bentônicos costeiros – Rede de Monitoramento de Habitat Bentônicos Costeiros – ReBentos [online]**. São Paulo: Instituto Oceanográfico da Universidade de São Paulo, 2015, p. 62-80.

SHEYKHMUSA, M.; MAHDIANPARI, M.; GHANBARI, H.; MOHAMMADIMANESH, F. et al. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Piscataway, v. 13, p. 6308-6325, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9206124>. Acesso em: 05 mar. 2021.

SHIRATSUCHI, Luciano; BRANDÃO, Ziany; VICENTE, Luiz; VICTORIA, Daniel; DUCATI, J.; OLIVEIRA, Ronaldo; VILELA, Marina. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. *In*: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, Á. V. de.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p 58-73.

SILVA, Elizabeth Dell’Orto; TOGNELLA, Mônica Maria Pereira; XAVIER, Alexandre Candido et al. Estimativas do Teor de Clorofila do Mangue da Baía de Vitória (ES) por meio de Dados Hiperespectrais. **Revista Brasileira de Geografia Física**, Recife, v. 13, n. 1, p. 131-142, jan./fev. 2020. Disponível em: <https://periodicos.ufpe.br/revistas/rbgefe/article/view/241961>. Acesso em: 29 mar. 2021.

SILVA, Janaina Barbosa da. **Territorialidade da pesca no estuário de Itapessoca-PE: técnicas, petrechos, espécies e impactos ambientais**. Orientadora: Dr^a Eugênia C. Pereira. 2006. 103 f. Dissertação (Mestrado em Geografia), Universidade Federal de Pernambuco, Recife, 2006. Disponível em: https://repositorio.ufpe.br/bitstream/123456789/6897/1/arquivo6920_1.pdf. Acesso em: 02 fev. 2021.

SILVA, Janaina Barbosa da. **Sensoriamento Remoto aplicado ao estudo do ecossistema manguezal em Pernambuco**. Orientadora: Dr^a Josiclêda Domiciano Galvíncio. 2012. 191 f. Tese (Doutorado Geografia), Universidade Federal de Pernambuco, Recife, 2012. Disponível em: <https://repositorio.ufpe.br/bitstream/123456789/10792/1/janaina.pdf>. Acesso em: 05 mar. 2021.

STEHMAN, Stephen V.; CZAPLEWSKI, Raymond L. Design and Analysis for Thematic Map Accuracy Assessment. **Remote Sensing of Environment**, Amsterdã, v. 64, n. 3, p. 331–344, dez. 1998. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425798000108>. Acesso em: 02 fev. 2021.

SIMARD, Marc. Radar remote sensing of mangrove forests. *In*: FLORES-ANDERSON, Africa I.; HERNDON, Kelsey E.; THAPA, Rajesh B.; CHERRINGTON, Emil. **The SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation**. Huntsville: National Space Science and Technology Center, 2019, p. 255-280.

STRAHLER, Alan H.; BOSCHETTI, Luigi; FOODY, Giles M.; FRIEDL, Mark A. et al. **Global land cover validation: Recommendations for evaluation and accuracy assessment of global land cover maps**. Luxembourg: European Communities, 2008. 58 p. Disponível em:

https://www.researchgate.net/publication/238580124_Global_Land_Cover_Validation_Recommendations_for_Evaluation_and_Accuracy_Assessment_of_Global_Land_Cover_Maps. Acesso em: 13 mar. 2021.

TOMLINSON, Philip Barry. **The botany of mangroves**. Cambridge: Cambridge University Press, 1986. 419p.

TOWNSEND, Philip. A. Estimating forest structure in wetlands using multitemporal SAR. **Remote Sensing of Environment**, v. 79, n. 2-3, p. 288–304, fev. 2002. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425701002802>. Acesso em: 9 fev. 2021.

UNITED STATES GEOLOGICAL SURVEY (USGS). **The spatial data transfer standard**. Draft: U.S. Geological Survey, 1990.

UNITED STATES GEOLOGICAL SURVEY (USGS). **Product Guide: Landsat4-7 Climate Data Record (CDR) Surface Reflectance**. Reston: U.S. Geological Survey, 2015.

WAHAB, Zulfa Abdul; KAMARUDIN, Norizah. Remotely Sensed Imagery Data Application in Mangrove Forest: A Review. **Pertanika Journal of Science and Technology**, Serdang, v. 26, n. 3, p. 899-922, jul. 2018. Disponível em: https://www.researchgate.net/publication/326768689_Remotely_Sensed_Imagery_Data_Application_in_Mangrove_Forest_A_Review. Acesso em: 9 fev. 2021.

WANG, Le; JIA, Mingming; YIN, Dameng; TIAN, Jinyan. A review of remote sensing for mangrove forests: 1956–2018. **Remote Sensing of Environment**, Amsterdã, v. 231, set. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425719302421>. Acesso em: 02 fev. 2021.

WANG, Y; IMHOFF, M. L. Simulated and observed L-HH radar backscatter from tropical mangrove forests. **International Journal of Remote Sensing**, v. 14, n. 15, p.2819-2828, jan. 1993. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01431169308904311>. Acesso em: 02 fev. 2021.

WINARSO, Gathot.; PURWANTO, A.D.; YUWONO, D.M. 2014. New mangrove index as degradation / health indicator using Remote Sensing data: Segara Anakan and Alas Purwo case study. **12th Biennial Conference of Pan Ocean Remote Sensing Conference**. Bali, 2014.

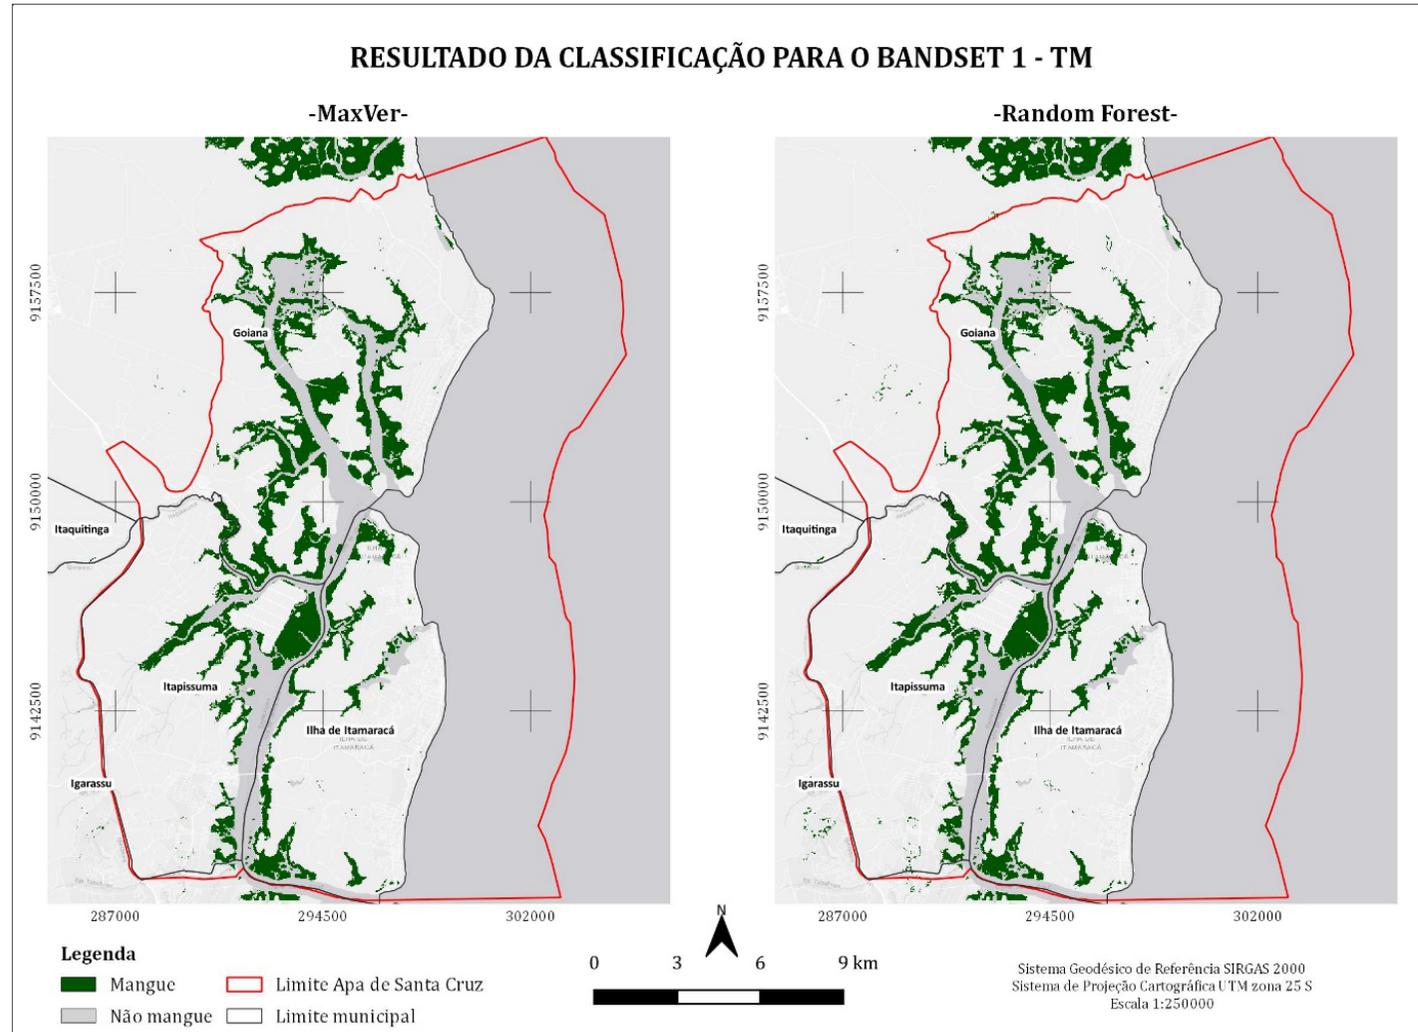
WALSH, Gerald. E. Mangroves: a review. **Ecology of Halophytes**, p. 51-147. Londres: Academic Press, 1974.

WOODHOUSE, Lain H. Introduction to Microwave Remote Sensing. Boca Raton: CRC Press, 2006. 398 p.

ZANOTTA, Daniel Capela; FERREIRA, Matheus Pinheiro; ZORTEA, Maciel. **Processamento de Imagens de Satélite**. São Paulo: Oficina de Textos, 2019. 307 p.

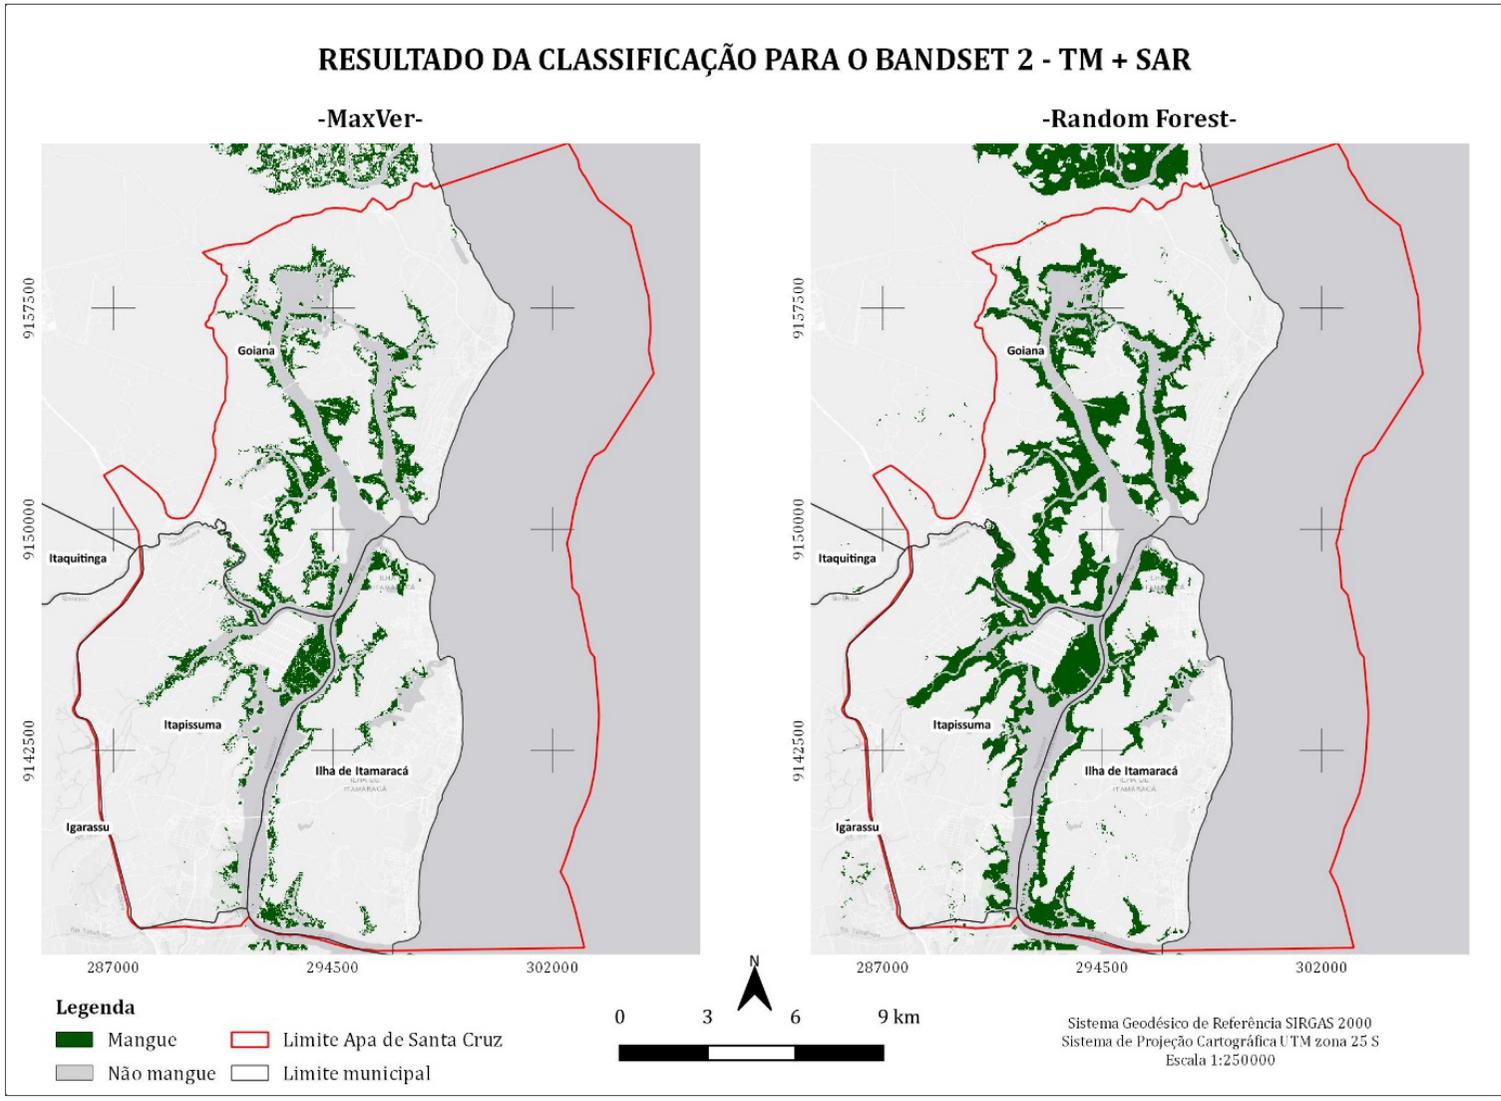
ZHANG, Keqi; THAPA, Bina; ROSS, Michael; GANN, Daniel. Remote sensing of seasonal changes and disturbances in mangrove forest: a case study from South Florida. **Ecosphere**, v. 7, n. 6, jun. 2016. Disponível em: <https://esajournals.onlinelibrary.wiley.com/doi/full/10.1002/ecs2.1366>. Acesso em: 12 mar. 2021.

APÊNDICE A – CLASSIFICAÇÕES DO *BANDSET 1* (TM)



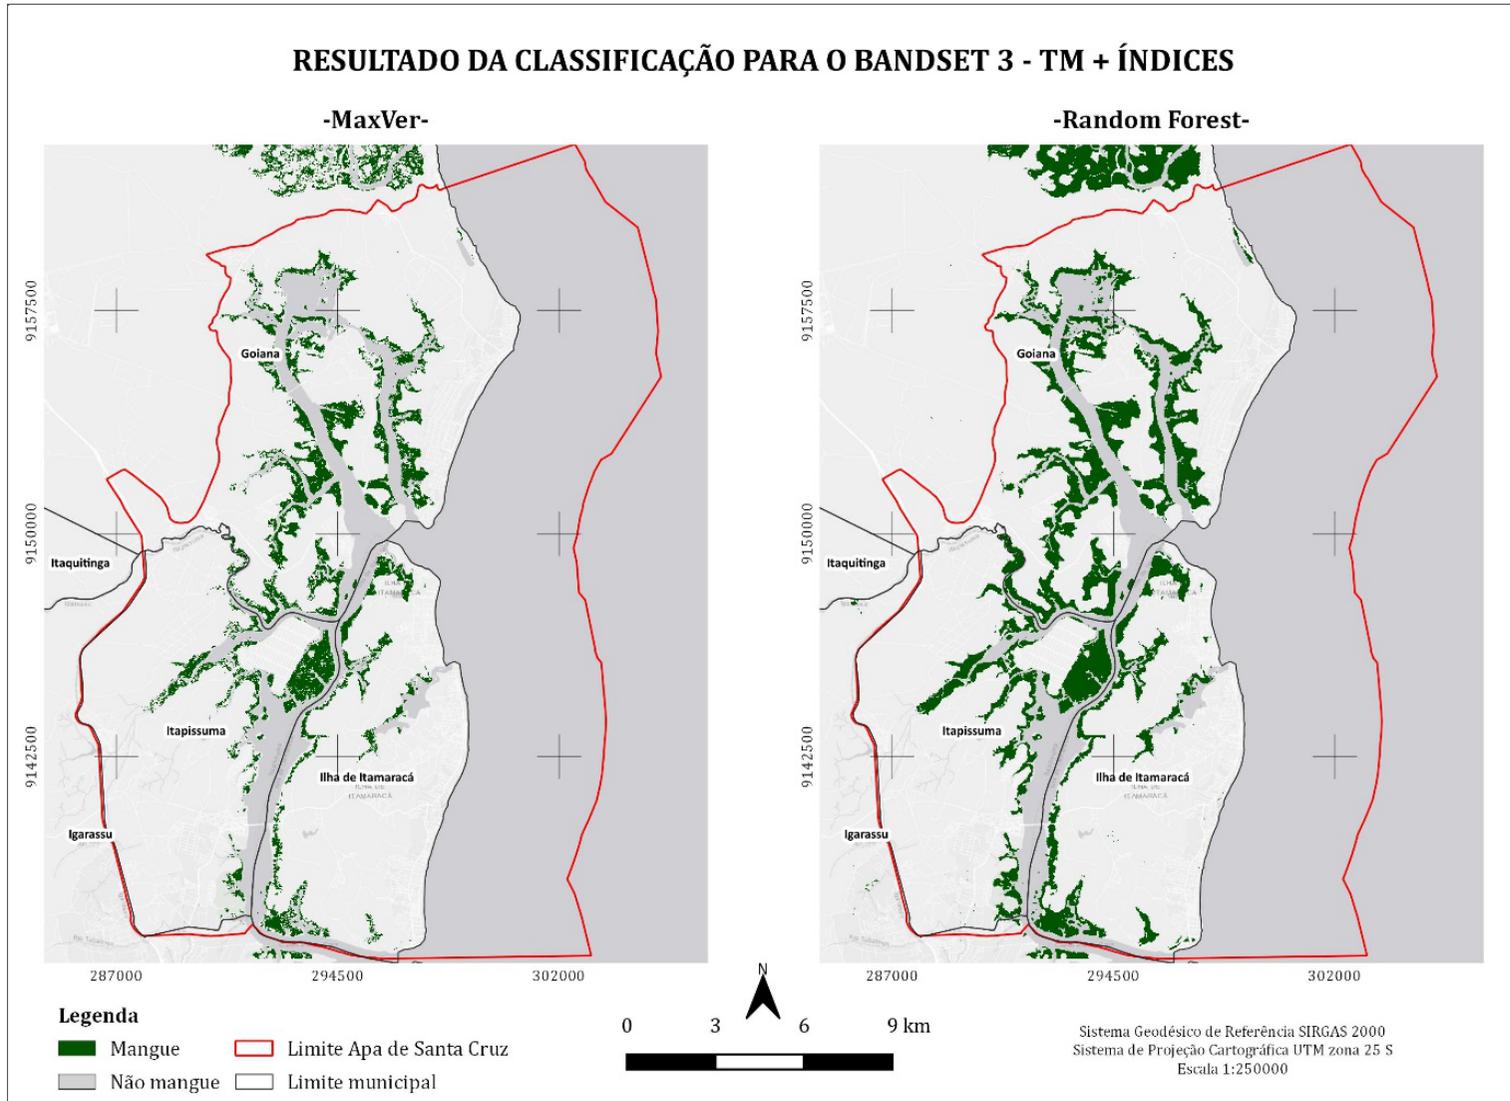
APÊNDICE B – CLASSIFICAÇÕES DO BANDSET 2 (TM + SAR)

RESULTADO DA CLASSIFICAÇÃO PARA O BANDSET 2 - TM + SAR



APÊNDICE C - CLASSIFICAÇÕES DO *BANDSET 3* (TM + ÍNDICES)

RESULTADO DA CLASSIFICAÇÃO PARA O *BANDSET 3* - TM + ÍNDICES



APÊNDICE D - CLASSIFICAÇÕES DO *BANDSET 4* (TM + SAR + ÍNDICES)

RESULTADO DA CLASSIFICAÇÃO PARA O *BANDSET 4* - TM + SAR + ÍNDICES

