



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ELABORAÇÃO DO MÉTODO DE ANÁLISE PARA CLASSIFICAÇÃO DA
FLORESTA DE MANGUEZAL DA REGIÃO DO DELTA DO PARNAÍBA,
POR MEIO DAS IMAGENS TEMPORAIS DO SENTINEL 1 E 2 E DAS
TÉCNICAS DE GEOPROCESSAMENTO**

Marcos Pereira da Silva

Tese de Doutorado

Brasília - DF
Fevereiro de 2023

PPGGEA-UnB ELABORAÇÃO DO MÉTODO DE ANÁLISE PARA CLASSIFICAÇÃO DA FLORESTA DE MANGUEZAL DA REGIÃO DO DELTA DO PARNAÍBA, POR MEIO DAS IMAGENS TEMPORAIS DO SENTINEL 1 E 2 E DAS TÉCNICAS DE GEOPROCESSAMENTO

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ELABORAÇÃO DO MÉTODO DE ANÁLISE PARA CLASSIFICAÇÃO DA FLORESTA
DE MANGUEZAL DA REGIÃO DO DELTA DO PARNAÍBA, POR MEIO DAS IMAGENS
TEMPORAIS DO SENTINEL 1 E 2 E DAS TÉCNICAS DE GEOPROCESSAMENTO**

Marcos Pereira da Silva

Orientadora: Profa. Dra. Ruth Elias de Paula Laranja
Coorientador: Prof. Dr. Osmar Abílio de Carvalho Júnior

Tese de Doutorado

Brasília - DF
Fevereiro de 2023

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ELABORAÇÃO DO MÉTODO DE ANÁLISE PARA CLASSIFICAÇÃO DA FLORESTA
DE MANGUEZAL DA REGIÃO DO DELTA DO PARNAÍBA, POR MEIO DAS IMAGENS
TEMPORAIS DO SENTINEL 1 E 2 E DAS TÉCNICAS DE GEOPROCESSAMENTO**

Marcos Pereira da Silva

Tese de Doutorado submetida ao Programa de Pós Graduação do Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Doutor em Geografia, área de concentração Gestão Ambiental e Territorial, opção Acadêmica.

Aprovado por:

Profa. Dra. Ruth Elias de Paula Laranja (GEA/UnB)
(Orientadora)

Prof. Dr. Osmar Abílio de Carvalho Júnior (GEA/UnB)
(Coorientador)

Prof. Dr. Rafael Rodrigues da Franca (UnB)
(Examinador Externo)

Prof. Dr. Sandro Nunes de Oliveira (IFB)
(Examinador Externo)

Prof. Dr. Michael Vandesteem Silva Couto (UFRN)
(Examinador Externo)

Brasília - DF, 17 de fevereiro de 2023

FICHA CATALOGRÁFICA

SILVA, MARCOS PEREIRADA. S586

REFERÊNCIA

SILVA, M. P. **Elaboração do método de análise para classificação da floresta de manguezal da região do Delta do Parnaíba, por meio das imagens temporais do Sentinel 1 e 2 e das técnicas de geoprocessamento.** 2023. 94 f. Tese (Doutorado em Geografia) – Instituto de Ciências Humanas, Universidade de Brasília, Distrito Federal, 2023.

CESSÃO DE DIREITOS

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor.

Marcos Pereira da Silva

Dedico este trabalho aos meus queridos
pais e irmãos.

AGRADECIMENTOS

Inicialmente, expresso minha gratidão a Deus, por minha existência e pelas oportunidades incríveis que tive.

Gostaria de agradecer, especialmente, à minha família, especialmente, à minha querida mãe, Maria de Jesus, e ao meu querido pai, João da Cruz, por serem a minha maior fonte de inspiração; e aos meus irmãos, Vania, Carlos, Lucas e Silvania, pelo carinho.

Minha gratidão à Núbia, que apesar de enfrentar desafios em sua própria atividade de pesquisa, sempre me encorajou e ofereceu seus préstimos de maneira excepcional.

Aos meus mentores: a Professora Doutora Ruth Elias de Paula Laranja; e o Professor Doutor Osmar Abílio de Carvalho Júnior, pela motivação e inspiração na concepção deste projeto de pesquisa, bem como pelos valiosos ensinamentos transmitidos.

Minha gratidão pela amizade, pela colaboração e pelos valiosos esclarecimentos a respeito dos métodos de pesquisa ao Professor Doutor Renato Fontes Guimarães e ao Professor Doutor Roberto Arnaldo Trancoso Gomes.

Gostaria de expressar minha gratidão pela amizade e convivência com os técnicos administrativos, Jorge Luiz Pereira e Agnelo José Camelo Pereira da Silva, pelos momentos felizes que compartilhamos.

Por último, mas não menos importante, expresso minha gratidão aos amigos e amigas do Laboratório de Sistemas e Informações Espaciais (LSIE): Nicholas, Mirian, Verônica, Nathalia Costa, Hugo, Felipe Barbosa, Anesmar, Hermínio, Daniella, Petrônio, Cristiane, Karina e Ivo, que de diversas maneiras, contribuíram para a realização deste trabalho.

RESUMO

A detecção automatizada e precisa de florestas de mangue é crucial para estratégias de conservação e tomada de decisão ao longo da extensa costa brasileira. Este estudo visa criar um conjunto de dados de floresta de mangue para processamento com Probability Density Components Analysis-Series Time e Minimum Noise Fraction, avaliar o modelo com diferentes filtros de eliminação de *speckle* e determinar o número ideal de imagens para uma detecção mais precisa. O objetivo principal desta pesquisa é analisar a eficácia das imagens do Sentinel-1 e Sentinel-2 para mapeamento das florestas de mangue, por meio da análise das características texturais e espectrais de cada conjunto de dados. A pesquisa se concentra em dois pontos principais: 1. Classificação de manguezais usando imagens Sentinel-1 com o histograma de frequência Probability Density Components Analysis, onde os métodos Random Forests e K Nearest Neighbor foram usados com acurácias de 89,43% e 88,29%, respectivamente. O método de janela deslizante com passo de 7x7 pixels foi considerado o mais eficaz; 2. Avaliação de imagens do satélite Sentinel-2 para mapeamento de manguezal na planície deltaica do rio Parnaíba. Neste estudo, os métodos Random Forests, K Nearest Neighbor e Support Vector Machine foram avaliados usando dados do Sentinel-2 para classificar as áreas de florestas de mangue. Os resultados mostraram que o método Random Forests obteve melhor desempenho para ambos os produtos Sentinel-1 (89,43%) e Sentinel-2 (96,78%), ligeiramente melhor que o K Nearest Neighbor. A metodologia desenvolvida neste estudo pode simplificar o processo de detecção, economizando tempo e recursos, e pode ser aplicada em outras regiões onde a cobertura de nuvens não permite precisão temporal.

Palavras-chave: detecção automatizada; series temporais; florestas de mangue; mapeamento; aprendizagem de máquinas.

ABSTRACT

Automated and accurate detection of mangrove forests is crucial for conservation strategies and decision-making along the extensive Brazilian coastline. This study aims to create a mangrove forest dataset for processing with Probability Density Components Analysis-Series Time and Minimum Noise Fraction, evaluate the model with different speckle elimination filters and determine the optimal number of images for more accurate detection. The main objective of this research is to analyze the effectiveness of Sentinel-1 and Sentinel-2 images for mapping mangrove forests, through the analysis of textural and spectral characteristics of each data set. The research focuses on two main points: 1. Classification of mangroves using Sentinel-1 images with the Probability Density Components Analysis frequency histogram, where the Random Forests and K Nearest Neighbor methods were used with accuracies of 89.43% and 88, 29%, respectively. The sliding window method with a step of 7x7 pixels was found to be the most effective; 2. Evaluation of Sentinel-2 satellite images for mapping mangroves in the deltaic plain of the Parnaíba river. In this study, the Random Forests, K Nearest Neighbor and Support Vector Machine methods were evaluated using Sentinel-2 data to classify mangrove forest areas. The results showed that the Random Forests method performed better for both Sentinel-1 (89.43%) and Sentinel-2 (96.78%) products, slightly better than K Nearest Neighbor. The methodology developed in this study can simplify the detection process, saving time and resources, and can be applied in other regions where cloud cover does not allow temporal accuracy.

Keywords: automated detection; time series; mangrove forests; mapping; machine learning.

“Tenho a impressão de ter sido uma criança brincando à beira-mar, divertindo-me em descobrir uma pedrinha mais lisa ou uma concha mais bonita que as outras, enquanto o imenso oceano da verdade continua misterioso diante de meus olhos”

(Isaac Newton)

LISTA DE FIGURAS

Figura 1 - Localização dos limites da APA-DP	20
Figura 2 - Floresta de mangue.....	23
Figura 3 – Localização da área de estudo.....	30
Figura 4 – Municípios que compõem a área de estudo	35
Figura 5 – Fluxograma metodológico do processamento de imagens	40
Figura 6 – Cubo de imagens 3D	41
Figura 7 – Fluxograma dos processamentos dos dados S-2	47
Figura 8 – Imagem do cubo 3D da série de bandas S-2	48
Figura 9 – Imagens resultantes do processo PDCA a partir das imagens Sentinel-1 polarização VV e VH (08/04/2017 a 21/05/2018).....	55
Figura 10 – Imagens componentes MNF resultantes do processamento das componentes PDCA	56
Figura 11 – Comparação dos valores das bandas PDCA e após a inversa MNF.....	57
Figura 12 – Assinaturas de densidade de probabilidade para a área de estudo	58
Figura 13 – Classificação (a) RF e (b) KNN.....	59
Figura 14 – Resultado do Índice Kappa para delimitação do manguezal	61
Figura 15 – Resultado dos diferentes estágios do espectro de pixels aleatórios: (a) dados primários; (b) filtro mediana e Savitzky-Golay	62
Figura 16 – Resultado dos diferentes estágios: (a) dados primários; (b) filtro mediana e Savitzky-Golay (composição SWIR – B12, B8A e B4).....	63
Figura 17 – Assinaturas espectrais usadas na classificação.....	63
Figura 18 – Assinaturas espectrais usadas na classificação.....	65
Figura 19 – Resultado do Coeficiente Kappa para delimitação do manguezal (SVM)	67
Figura 20 – Diferença entre as a classificação RF, KNN e SVM: delimitação do mangue.....	68

LISTA DE TABELAS

Tabela 1 – População residente, por ano, segundo e por município (1980-2010).....	34
Tabela 2 – Especificações do modo IW imagens Sentinel 1	41
Tabela 3 – Características das imagens do Cubo S-2	48
Tabela 4 – Teste McNemar entre duas classificações	52
Tabela 5 – Avaliação de precisão dos modelos RF e KNN do mapeamento das extensões de manguezal. Melhor resultado indicado em negrito.....	60
Tabela 6 – Avaliação de precisão da classificação de RF, KNN e SVM, no mapeamento das extensões de manguezal. Melhor resultado em negrito	65
Tabela 7– Avaliação da precisão a partir da verdade do solo	66
Tabela 8 – Avaliação da diferença entre os resultados da classificação com o teste McNemar realizado com 5.000 pontos da amostra.....	67

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas
APA-DP	Área de Proteção Ambiental Delta do Parnaíba
CCM	Complexo Convectivo de Mesoescala
COI	Comissão Oceanográfica Intergovernamental
CPRM	Companhia de Pesquisa de Recursos Minerais
DHN	Diretoria de Hidrografia e Navegação
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESA	European Space Agency
GRDH	Ground Range Detected High Resolution
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Metrologia, Qualidade e Tecnologia
INPE	Instituto Nacional de Pesquisas Espaciais
KNN	K-Nearest Neighbor
LSIE	Laboratório de Sistemas e Informações Espaciais
MMA	Ministério do Meio Ambiente
MNF	Minimum Noise Fraction
MSI	Multispectral Imager
NASA	National Aeronautics and Space Administration
PDCA-ST	Probability Density Components Analysis-Series Time
RF	Random Forest
ROI	Regiões de Interesse
SAR	Synthetic Aperture Radar
SAR	Synthetic Aperture Radar
SIG	Sistemas de Informação Geográfica
SVM	Support Vector Machine
VCAN	Vórtice Ciclônico de Altos Níveis
ZCTI	Zona de Convergência Intertropical

Sumário

RESUMO	vii
ABSTRAT	viii
LISTA DE FIGURAS	x
LISTA DE TABELAS	xi
LISTA DE ABREVIATURAS E SIGLAS	xii
1 INTRODUÇÃO	15
1.1 Hipóteses.....	17
1.2 Objetivos	18
1.2.1 Objetivo geral	18
1.2.2 Objetivos específicos.....	18
1.3 Estrutura da tese.....	18
2 REVISÃO DA LITERATURA	20
2.1 Florestas de mangue.....	22
2.2 A contribuição do sensoriamento remoto.....	25
2.3 Radar, RAR, SAR e ótico	28
3 ÁREA DE ESTUDO	29
4 MATERIAIS E MÉTODOS	36
4.1 Pesquisa bibliográfica e fontes de pesquisa	36
4.2 Séries temporais como aporte para o monitoramento	36
4.3 Aquisição das imagens do sensor Sentinel-1	38
4.4 Aquisição das imagens do sensor Sentinel-2	38
4.5 Processamento das imagens Sentinel-1	39
3.1.3 Classificação.....	49
5 RESULTADOS	54
5.1 Sentinel-1	54
5.1.1 PDCA e MNF.....	54
5.1.2 Classificação.....	57
5.1.3 Análise de acurácia	60
5.2 Sentinel-2	62
5.2.1 Filtragem do ruído.....	62
5.2.2 Classificação: RF, KNN e SVM	64
5.2.3 Análise de acurácia	65
6 DISCUSSÃO	70
7 CONCLUSÃO	72
REFERÊNCIAS	75

1 INTRODUÇÃO

A tecnologia de sensoriamento remoto tem-se tornado uma importante fonte de informação sobre a superfície da Terra desde o seu advento. Na Primeira Grande Guerra, as observações por fotografia aérea com câmeras rudimentares em aviões foram as precursoras dos modernos sistemas de detecção remota. Posteriormente, na Segunda Grande Guerra, técnicas de fotografias aéreas mais desenvolvidas foram utilizadas para o mapeamento e a caracterização das condições costeiras para Invasão da Normandia (Dia D), sendo empregadas películas de infravermelho para identificar o que era vegetação e o que era camuflagem (ESA, 2009).

A partir de então, o desenvolvimento de tecnologia de detecção remota não fotográfica avançou rapidamente, após a colocação em órbita do primeiro satélite cartográfico óptico, o LADSAT-1, em 1972 (ESA, 2009).

É difícil conceber, atualmente, pesquisas científicas sobre superfície terrestre sem esse tipo de tecnologia, importantes em ações como: monitoramento de áreas inundadas; detecção de atividades geomorfológicas; estimativa de produção agrícola; monitoramento da cobertura vegetal; previsão do tempo; ordenamento do território; detecção de incêndio; processo de desmatamento ou desertificação; além de ser fonte de informações para a gestão de paisagem (COPERNICUS, 2018).

Logo, é cada vez mais imprescindível o uso de dados orbitais para uma compreensão mais acurada dos parâmetros bio e geofísicos. Nessa direção, dados de satélites ópticos têm sido empregados principalmente para a classificação de cobertura do solo e detecção de alterações (PFLUGMACHER, 2007).

Os comprimentos de onda utilizados não podem penetrar nas nuvens, e uma vez que os dados recolhidos são o reflexo do sol, as imagens obtidas no acúmulo de nuvens nem sempre são adequadas para estudos de superfície.

Com efeito, o sensoriamento remoto baseado em sensores ópticos é altamente dependente da condição da atmosfera, porquanto os sensores ópticos se baseiam na reflexão da radiação solar. Dessa forma, a energia solar não alcançando o objeto analisado, não pode ser mensurada, limitando o seu uso durante o dia, e sem nuvens. Na faixa equatorial do planeta, praticamente é coberta por nuvens 60% do ano, como é o caso do litoral Norte e da porção norte do litoral Nordeste do Brasil (ARAÚJO, 2015). Por constituir uma área de atuação da Zona de Convergência Intertropical (ZCT), o sensor óptico para essa região é limitante (GRANDONI, 2013).

Assim, a alternativa mais plausível é a tecnologia de *Synthetic Aperture Radar* (SAR), dentre cujas vantagens está a independência da radiação solar, pois o radar é um emissor ativo e sua radiação penetra nas composições atmosféricas, permitindo a detecção da superfície da Terra mesmo em dias nublados.

A observação contínua, a partir de séries temporais de imagens de radar, possibilita o observador tecer análises sobre o desenvolvimento sazonal da vegetação selecionada, relevante para entendimento da sua dinâmica, como também compreender o seu ciclo dentro das variações climáticas, suscitando a tomadas de decisões.

Um dos propósitos desta tese é a pesquisa da literatura sobre a classificação de áreas costeiras, com destaque para as florestas de mangue, a partir de dados de radar. Dentre as imagens SAR e óticas, destacam-se as Sentinel-1, com cobertura frequente. Tais imagens não são afetadas pelas condições climáticas, mas podem mostrar as assinaturas de condições no momento da captura na superfície dos oceanos.

A constelação Sentinel-1 consiste em dois satélites idênticos, Sentinel-1A e Sentinel-1B, que foram lançados em 2014 e 2016, respectivamente. A principal diferença entre os referidos satélites é que eles estão em órbitas diferentes, o que aumenta a cobertura da Terra. Aliás, o Sentinel-1A está em uma órbita polar heliosíncrona, enquanto o Sentinel-1B, em uma órbita inclinada (COPERNICUS, 2018).

No âmbito do sensoriamento remoto, a fusão de dados possibilitou melhora na precisão, daí porque muitas pesquisas têm explorado esse método, pois com a interoperabilidade e a complementaridade de diferentes sensores, obtêm-se resultados mais acurados em aplicações no monitoramento ambiental, repercutindo na identificação de ameaças, no monitoramento de culturas e na classificação da cobertura do solo. Em um processo de classificação, adicionando-se imagens multiespectrais para uma série temporal SAR, melhora-se a precisão da classificação (WASKE; LINDEN, 2008).

Por oportuno, nesta pesquisa, utilizaram-se dados óticos da constelação Sentinel-2, constituindo dois satélites iguais, quais sejam Sentinel-2A e Sentinel-2B. Aquele foi lançado em junho de 2015, e está em uma órbita polar heliosíncrona, a uma altitude de cerca de 786 km, enquanto o Sentinel-2B foi lançado em março de 2017, e está na mesma órbita do Sentinel-2A. A principal diferença entre os dois satélites é que eles foram construídos por diferentes empresas e, portanto, podem ter algumas diferenças técnicas. Ademais, a posição orbital do Sentinel-2B é ligeiramente desigual, o que permite a cobertura de áreas diferentes (COPERNICUS, 2018).

Isso posto, as diversas propriedades físicas dos sensores SAR e ópticos fornecem informações auxiliares sobre o objeto em estudo, e podem ampliar a precisão dos resultados da classificação significativamente. Entrementes, esse campo particular de estudo ainda permanece aberto para mais investigações, particularmente, no tocante à disponibilização de dados como séries temporais mais longas de SAR, ensejando o desenvolvimento de novas pesquisas (SANDBERG, 2016).

Em uma superfície sob constante transformação, as imagens de satélite representam uma solução rápida para o monitoramento do solo. Por sinal, as interações antrópicas, concomitantemente com os processos naturais, são responsáveis por essas mudanças, e seus efeitos devem ser pesquisados para evitar danos, nomeadamente para as florestas de mangue, que do substrato à copa, constituem grandes filtros naturais e armazenadores de carbono, além de proteção natural contra os processos erosivos costeiros (SILVA, 2013).

Nessas áreas de florestas de mangue, as características da vegetação e as mudanças sazonais diferem de outras espécies vegetais homogêneas, que permanecem em sua maior parte em um substrato lamoso, o qual, segundo a geomorfologia, é denominado de *planície de maré*. Com efeito, está sob a influência direta da dinâmica costeira e sua sazonalidade.

Tais processos suscitam mudanças capazes de definir novas medidas de caracterização, podendo ser utilizadas na classificação de cobertura da terra. Dessa forma, reputa-se a necessidade de desenvolver métodos para o mapeamento da cobertura da terra que sejam adequados para essas áreas. Nessa perspectiva, uma metodologia de estudo ideal é a utilização de dados das constelações Sentinel em séries temporais.

1.1 Hipóteses

Como proposta a ser estudada e aplicada nesta pesquisa de tese, investigam-se as seguintes hipóteses:

- a aplicação de técnicas de detecção por sensoriamento remoto, utilizando dados das constelações Sentinel-1 e 2, permitirá a geração de informações úteis para a análise da dinâmica costeira, com foco na floresta de mangue.
- os atributos únicos dos dados SAR podem ser transformados em dados de frequência, mantendo suas características em relação às unidades da paisagem costeira, como o uso da terra e dinâmica dos corpos hídricos.

1.2 Objetivos

1.2.1 Objetivo geral

O objetivo geral da presente tese é analisar a eficácia das imagens do Sentinel-1 e Sentinel-2 para o mapeamento das florestas de mangue, por meio da análise das características texturais e espectrais de cada conjunto de dados.

1.2.2 Objetivos específicos

1. Aprimorar modelos de processamento para os dados do Sentinel-1 e Sentinel-2, incluindo as correções necessárias e a seleção de bandas relevantes para o mapeamento das florestas de mangue;
2. aferir modelos de classificação de imagens separadamente para os dados do Sentinel-1 e Sentinel-2, utilizando algoritmos de aprendizado de máquina (*machine learning*);
3. avaliar a precisão dos modelos de classificação desenvolvidos para cada conjunto de dados, comparando os resultados obtidos com dados de referência terrestre, mediante métrica de precisão *Kappa* e teste McNemar;
4. comparar a eficácia das imagens do Sentinel-1 e Sentinel-2 para o mapeamento da vegetação de mangue, com base nos resultados obtidos em relação à precisão e aos classificadores utilizados.

1.3 Estrutura da tese

Como proposta de tese, optou-se pelo formato tradicional, sistematizado em capítulos conforme a ordem dos objetivos, visando a alcançar uma sequência lógica de estudo. *A priori*, pode ser produzida no formato normatizado pela UnB, e posteriormente formatada para os periódicos científicos a serem submetidos para publicação.

A partir dessa metodização, os capítulos serão dispostos em sequência vertical, e a partir dos resultados parciais oriundos de cada um deles, pretende-se chegar ao resultado final do trabalho de tese, respondendo às indagações pertinentes.

Nessa direção, a tese organizar-se-á, inicialmente, em sete capítulos, sendo o Capítulo 1, constituído por introdução, hipótese e objetivos. O Capítulo 2 trata das bases teóricas, fundamentando-se na literatura que embasará esta investigação, lançando uma luz sobre a problemática da pesquisa. O Capítulo 3 aborda a caracterização da área de estudo, abrangendo os aspectos da paisagem. O Capítulo 4 contém a metodologia da pesquisa e a forma como foram analisados e interpretados os resultados. O Capítulo 5 relata e discute os resultados obtidos,

enquanto o Capítulo 6 apresenta as considerações finais, incluindo propostas para o direcionamento futuro de pesquisas nesse âmbito. Finalmente, seguem as Referências citadas ao longo do texto.

2 REVISÃO DA LITERATURA

O Brasil ocupa a décima sexta posição em extensão litorânea do mundo, compreendendo uma faixa com mais de 8.500 km (BRASIL, 2017). Assim, ao norte, limita-se com foz do rio Oiapoque, no município de Oiapoque, no Amapá; e ao sul, com foz do rio Arroio Chuí, no município de Santa Vitória do Palmar, Rio Grande do Sul. Toda a sua extensão é intercalada por áreas caracterizadas em pontos populacionais habitados e vazios, os quais são amplamente ameaçados por pressões antrópicas.

O litoral do Brasil está dividido em grandes regiões geográficas, assim delimitadas: o litoral Norte compreende da foz do rio Oiapoque à baía de São Marcos, em São Luís – MA; o litoral Nordeste abrange da baía de São Marcos à baía de Todos os Santos, em Salvador – BA; o litoral Oriental ou Leste vai de Salvador – BA à Ilha do Cabo Frio, em Arraial do Cabo – RJ; o litoral Sudeste corresponde à faixa da Ilha do Cabo Frio ao Cabo de Santa Marta, em Laguna – SC; e o litoral Sul estende-se do Cabo de Santa Maria à foz do Arroio Chuí (SILVEIRA, 1964).

Propriamente cerca de 49,94% da Área de Proteção Ambiental Delta do Parnaíba (APA-DP), por volta de 1.539,46 km², está inserido na área de pesquisa (Figura 1), compreendendo 22,57% das florestas de mangue. Embora os deltas representem apenas 5% da superfície terrestre mundial, mais de 550 milhões de pessoas vivem em áreas deltaicas. Aliás, os deltas são áreas de subsistência elegidas, que apresentam terreno plano, solos aluviais férteis, acessos a recursos fluviais e marinhos, além de rica biodiversidade de zonas húmidas, entre outras vantagens. São, no entanto, ameaçados por numerosos processos internos e externos (KUENZER *et al.*, 2015).

Figura 1 - Localização dos limites da APA-DP



Fonte: IBGE (2022); MMA (2018).

A APA-DP corresponde à planície deltaica do rio Parnaíba, e está inserida no Macrocompartimento Costa Semiárida Norte no litoral Nordeste, abrangendo parte dos estados do Maranhão, Piauí e Ceará. Historicamente, como toda região do litoral piauiense e dos municípios dos outros estados fronteiriços, esteve ligada ao modo de vida pesqueira. O processo de ocupação ocorreu do interior para o litoral. Caracteriza-se por aspectos como: agricultura de subsistência; monocultura frutífera; pecuária extensiva; extrativismo vegetal; pesca; e turismo.

A crescente pressão da urbanização, da agricultura, da pecuária, da aquicultura e do turismo em ambientes costeiros em todo o mundo, assim como os serviços dos ecossistemas inerentes aos ambientes de contato marinho e continental, em razão de sua fragilidade, evidenciam a necessidade de monitoramento e gerenciamento de forma eficaz e automática desses ambientes.

Em verdade, observa-se que os impactos ambientais estão atrelados aos conflitos de uso sobre os ambientes costeiros e, nessa lógica, são necessários mecanismos mitigadores para esses processos, que deverão passar pela educação ambiental e melhoria das políticas para orientar a ocupação.

Dentre as fitofisionomias da área, pretende-se analisar o mangue permanentemente inundado, com substrato lamoso e parcialmente inundado, bem como as principais fisionomias ou unidades fitogeográficas de restinga e vegetação de tabuleiro costeiro, composta nessa região por Caatinga, Cerrado, Mata dos Cocais, Matas Ciliares e áreas agrícolas.

O processo de ocupação acelerada, imediatista e sem o devido monitoramento, desconsiderando as características ambientais das florestas de mangue, vem gerando impactos significativos. Por ser uma área com características continentais e marítimas, carece de fiscalização dos recursos naturais e um planejamento adequado para a ocupação desses espaços.

Essa negligência sobre o patrimônio natural resultou em múltiplos impactos ambientais negativos, incluindo a degradação ambiental e os conflitos de uso, que afetam diretamente a qualidade de vida das pessoas. Deveras, a ausência de técnicas modernas de monitoramento e delimitação pode repercutir em graves consequências, gerando degradação e mudanças físico-naturais aceleradas pelas atividades antrópicas, sobretudo o desmatamento da cobertura vegetal. Tais alterações afetam o meio físico, biótico e antrópico.

Portanto, as condições naturais e antrópicas conferem um caráter dinâmico a esses espaços, com contradições na forma de uso e ocupação. Tendo isso em vista, a gestão dos ambientes costeiros, embasada na dinâmica ambiental, visa a observar, caracterizar e

compreender a funcionalidade de seus componentes, levando em consideração a intensidade das relações entre eles.

2.1 Florestas de mangue

Os ecossistemas florestas de mangue ou manguezais (figura 2) estão distribuídos na região intermarés, entre o mar e a terra, nas regiões tropicais e subtropicais do mundo, entre latitudes de aproximadamente 30° N e 30° S, contribuindo para o sequestro de carbono (KRISTENSEN *et al.*, 2008; YONG *et al.*, 2011; HUNG; TIEN; VAN LUONG, 2015; SPALDING *et al.* 1997; ALONGI, 2002; GIRI *et al.*, 2010; THOMAS *et al.*, 2017); os ciclos de nutrientes (FRIESEN; DUNN; FREEMAN, 2018; RODRÍGUEZ; LUNA; HERNÁNDEZ, 2018); os serviços ecossistêmicos (VO *et al.*, 2012; BARBIER, 2016); a proteção costeira contra tempestades (BLANKESPOOR; DASGUPTA; LANGE, 2016; DASGUPTA *et al.*, 2019); os berçários para peixes e o equilíbrio populacional de peixes marinhos (EL-REGA; IBRAHIM, 2014; ANNEBOINA; KUMAR, 2017).

As florestas de mangue crescem em condições ambientais adversas, como alta salinidade, alta temperatura, marés extremas, alta sedimentação e solos anaeróbios enlameados (SAINTILAN *et al.*, 2014; CRAFT, 2016; FARIDAH-HANUM *et al.*, 2019; RAYEGANI *et al.*, 2019). Acredita-se que sua distribuição global seja delimitada pelas principais correntes oceânicas e pela isoterma de 20° C da água do mar no inverno (ALONGI, 2009).

Estima-se que atualmente, as áreas de florestas de mangue do mundo reduziram-se à metade do que eram antes, e muito do que resta está em condições de degradação. De fato, os *habitats* costeiros em todo o mundo estão sob pressões antrópicas e sujeitos às intempéries naturais (SPALDING *et al.*, 1997; SPIRES, 1999).

O declínio contínuo dessas áreas é causado pela conversão para a agricultura (principalmente a rizicultura), a aquicultura, o turismo, a expansão urbana e a exploração sem gerenciamento, além de desmatamento para extração de lenha e poluição por óleo (ALONGI, 2002; GIRI *et al.*, 2008; AHMED; GLASER, 2016; ROMANACH *et al.*, 2018; BOSMA *et al.*, 2014; AKANNI *et al.*, 2018).

Impende salientar que cerca de 35% dos manguezais foram perdidos de 1980 a 2000, e as florestas vêm diminuindo a um ritmo mais rápido do que florestas tropicais e recifes de corais (DUKE *et al.*, 2007).

Concebe-se que o aumento relativo do nível do mar pode ser a maior ameaça para as florestas de mangue (GILMAN *et al.*, 2008). Nessa direção, as previsões sugerem que 30% a 40% das zonas úmidas costeiras e 100% das florestas de mangue podem se perder nos próximos

100 anos se a atual taxa de perda continuar. Por certo, bens e serviços ecossistêmicos importantes – a exemplo de barreira natural, sequestro de carbono e biodiversidade –, fornecidos por florestas de mangue, serão diminuídos ou perdidos (DUKE *et al.*, 2007).

Figura 2 - Floresta de mangue



Aspectos da vegetação de mangue: (a) Manguezal do Delta do Rio Paraíba, com árvores da espécie mangue vermelho (*Rhizophora mangle*) chegando a medir até 20 metros de altura.; (b) Igarapé que separa a ilha Grande de Santa Isabel da ilha do Bananal; (c) Feições das raízes de mangue em baixa maré; (d) Raízes de mangue em maré alta; (e) Em muitos pontos na área Sul dos mangues mais próximos da zona rurais do município de Ilha Grande, encontra-se ambiente em que o mangue é derrubado para agricultura, e a madeira utilizada como lenha (direita da foto).

Fonte: Acervo pessoal. SILVA, 2013.

Além de servir de refúgios importantes para peixes, crustáceos e aves, das florestas de mangue também se extrai a madeira para combustão e uso na construção civil (FERREIRA; GANADE; LUIZ DE ATTAYDE, 2015; HOGARTH, 2017; MARTIN *et al.*, 2015; VALDERRAMA-LANDEROS *et al.*, 2018).

Em toda distribuição de mangues no mundo, o impacto final sobre florestas de mangue varia conforme a localização, e resulta de uma interação complexa entre o aumento do nível do mar e as mudanças na bacia hidrográfica, incluindo a diminuição do escoamento continental devido ao regime de chuvas alterado (DAI *et al.* 2009; GODOY; LACERDA, 2015).

As florestas de mangue, incluindo os solos associados, poderiam sequestrar, aproximadamente, 22,8 milhões de toneladas de carbono por ano. Cobrindo apenas 0,1% da superfície continental da Terra, essas florestas representam 11% do total de entrada de carbono terrestre no oceano, e 10% do carbono terrestre orgânico dissolvido exportado para o oceano (WHITTAKER; LIKENS, 1975; JENNERJAHN; ITTEKOT, 2002; DITTMAR *et al.*, 2006).

Os manguezais estão entre as florestas mais ricas em armazenamento de carbono na região tropical do planeta, contendo, em média, 1.023 mg de carbono por hectares (DONATO *et al.*, 2011). As florestas de mangue são, ainda, sumidouros de carbono altamente eficientes nos trópicos (KOMIYAMA; ONG; POUNGPARN, 2008).

O rápido desaparecimento e a degradação dos manguezais pode ter consequências negativas para a transferência de materiais aos sistemas marinhos, interferindo na composição atmosférica e no clima (BOUILLON, 2011).

Isso porque esses ambientes são sensíveis às mudanças climáticas, que provocam elevação do nível do mar e aumento da temperatura (ROMAÑACH *et al.*, 2018; CHOW, 2017). Dada a importância natural e econômica das florestas de mangues, na atualidade, são foco de preocupação não somente da comunidade científica como também do Programa das Nações Unidas para o Meio Ambiente (VAN BOCHOVE *et al.*, 2014).

Diante do exposto, atina-se que as florestas de mangue estão entre os ecossistemas mais produtivos e biologicamente importantes do mundo, porquanto fornecem bens e serviços ecossistêmicos consideráveis e únicos à sociedade humana, bem como aos sistemas costeiros e marinhos.

Adicionalmente, as florestas ajudam a estabilizar as margens e reduzir o impacto devastador de desastres naturais, como *tsunamis* e furacões. Outrossim, fornecem áreas de reprodução e de enfermagem para espécies marinhas e pelágicas, como também alimentos, medicamentos, combustíveis e materiais de construção para as comunidades locais.

2.2 A contribuição do sensoriamento remoto

O monitoramento de manguezais com dados de sensoriamento remoto é amplamente empregado devido à sua visão sinótica, rapidez e alta relação custo-benefício. Na verdade, as imagens óticas são de fácil interpretação, embora prejudicadas pela cobertura de nuvens e dependência da luz solar (SCHMITT; TUPIN; ZHU, 2017).

Em contraposição, as imagens de Radar de Abertura Sintética (SAR) são adquiridas independentemente da cobertura de nuvens e da luz do dia (HONG *et al.*, 2014; STEELE-DUNNE *et al.*, 2017; RÜETSCHI; SCHAEPMAN; SMALL, 2017; RAJAH; ODINDI; MUTANGA, 2018).

O uso do sensoriamento remoto consiste em uma vantagem técnica para a identificação de grandes áreas de cobertura de mangue, visto que as características de ambientes inundáveis com substrato muito macios dificultam sobremodo o acesso. Assim, a capacidade de precisar com exatidão a partir de dados de satélite auxilia muito essa categoria pesquisa (FRIESS; WEBB, 2014; GIORDAN *et al.*, 2018; GUO *et al.*, 2017; HEUMANN, 2011a; PHAM *et al.*, 2018; UDDIN; MATIN; MEYER, 2019).

As aplicações do sensoriamento remoto na detecção de manguezal são inúmeras, dentre as quais se destacam: fornece informações sobre inventários de espécies (KOVACS *et al.*, 2010; KOVACS; WANG; FLORES-VERDUGO, 2005); monitoramento de alterações (FLORES-DE-SANTIAGO *et al.*, 2016; HEENKENDA *et al.*, 2015); e avaliação do ecossistema (MCCARTHY; MERTON; MULLER-KARGER, 2015).

Os melhoramentos da exatidão de classificação de manguezais são de importância ímpar no monitoramento desse tipo de vegetação. Aliás, o mapeamento de florestas de mangue mediante técnicas de sensoriamento remoto baseadas em satélite é o método mais plausível para classificação, dentre os usados atualmente (CHADWICK, 2011; MUKHERJEE *et al.*, 2014; VALDERRAMA-LANDEROS *et al.*, 2018; WALTERS *et al.*, 2008).

As imagens SAR têm sido empregadas para caracterizar, mapear e monitorar manguezais (KUENZER *et al.*, 2011; LUCAS *et al.*, 2014; THOMAS *et al.*, 2014). A propósito, estudos de manguezais que utilizam SAR – como Sentinel-1 – apresentam resultados consideráveis (CASTILLO *et al.*, 2017).

Muitos estudos têm adotado a banca C em florestas tropicais (FIEUZAL; BAUP, 2016; HALDAR *et al.*, 2016; KUMAR *et al.*, 2017; RÜETSCHI; SCHAEPMAN; SMALL, 2017;

WHELEN; SIQUEIRA, 2018), devido à interação do comprimento de ondas com as menores partes do dossel, das folhas e dos pequenos galhos (HUANG *et al.*, 2010; HONG *et al.*, 2014).

Atualmente, é significativa a melhoria da resolução espacial dos sensores disponíveis em órbita – aqui se inclui o sensor *Multispectral Imager* (MSI), transportado no Sentinel-2 (S-2). Tais imagens óticas facultam a extração dos tipos de cobertura do solo e, principalmente, da vegetação, a partir de seus produtos, compostos por várias bandas espectrais. À vista disso, é possível identificar os ambientes no solo a partir de métodos de classificação supervisionados ou não supervisionados (BELGIU; CSILLIK, 2018; BLASCHKE, 2010; DUCART *et al.*, 2016; HEUPEL; SPENGLER; ITZEROTT, 2018; LEBOURGEOIS *et al.*, 2017).

As imagens óticas devem passar por um pré-processamento adequado, etapa fundamental para garantir a idoneidade da classificação antes da extração dos dados sobre o que pode ser ou não cobertura vegetal, em razão da presença de nuvens e aerossóis (LIPING; YUJUN; SAEED, 2018; SIDHU; PEBESMA; CÂMARA, 2018; WULDER *et al.*, 2018).

Os manguezais contam com características únicas de refletância espectral, então o sensoriamento remoto é eficiente na distinção desse tipo de vegetação, com base nas particularidades de cada caso (CARDOSO; SOUZA; SOUZA-FILHO, 2014; ROSLANI *et al.*, 2013; SANTIAGO; KOVACS; LAFRANCE, 2013; WANG *et al.*, 2019; XIA *et al.*, 2018; XIE; SHA; YU, 2008).

Em face de sua relevância em áreas de existência, denota-se uma demanda por estudos que avaliem adequadamente sua distribuição e dinâmica. Portanto, mapear e monitorar esse ecossistema é uma tarefa difícil, executada, em sua maioria, por sensoriamento remoto, com dados de campo atinentes a determinado período de tempo (THOMAS *et al.*, 2017).

No tocante ao inventariado *in loco*, por tratar-se de uma região pantanosa, a realização de campo é cara e demorada. Outrossim, as iniciativas anteriores não dispunham de dados com maior nível de detalhamento, uma vez que foram utilizados baixa resolução espacial, de 1 km, por exemplo, além da dificuldade na disponibilização de dados (ALONGI, 2002; GIRI *et al.*, 2007).

Apesar das limitações de pesquisas anteriores, o sensoriamento remoto desempenha uma atribuição fundamental no processo de diagnóstico e monitoramento, atribuindo à pesquisa rapidez e eficiência. Hodiernamente, existe uma disponibilidade maior de dados gratuitos de satélite, somados aos avanços em *hardware* e *software*, permitindo o processamento de um grande volume de dados.

Nessa perspectiva, imagens de SAR proporcionam um benefício maior que as imagens ópticas, como visto no capítulo anterior, tendo em vista a habilidade de colher informações da superfície, independentemente das condições atmosféricas e da iluminação solar. A propósito, o radar de banda C, Sentinel-1, permite o monitoramento de forma sistemática e gratuita. Por conseguinte, o conjunto de dados em séries temporais propicia a detecção de mudanças nas florestas de mangue ao longo do tempo.

Assim, alude-se que a disponibilidade de informações atualizadas sobre o *status* e as condições desse importante ecossistema é inescusável para o gerenciamento dos recursos referentes aos manguezais de maneira sustentável (GIRI *et al.*, 2007).

Nessa sequência, os dados Sentinel representam um indicador utilizado no sensoriamento remoto para classificação dos solos e caracterização de sua estrutura, funcionalidade e dinâmica. A ideia é que a alteração seja refletida nas séries temporais.

Em ambientes costeiros, a detecção de mudanças é de intrínseco interesse para as pesquisas, por efeito da degradação do ambiente e da saúde humana. O estudo das mudanças no uso e na cobertura da terra é um sustentáculo considerável para o planejamento e a utilização adequada dos recursos naturais, como também para a sua gestão.

Métodos tradicionais de pesquisa, como coleta de dados, censos, análise de amostragem não são suficientes para estudos multicomplexos, uma vez que grande parte dos problemas frequentemente apresentados na esfera ambiental são de ampla complexidade para se lidar com o conjunto de informações multidisciplinares. Diante dessa premissa, tecnologias como sensoriamento remoto e Sistemas de Informação Geográfica (SIG) fornecem dados que oportunizam o estudo e monitoramento da dinâmica dos recursos naturais com vistas a uma gestão ambiental.

Na verdade, o sensoriamento remoto tornou-se uma ferramenta marcante, aplicável ao desenvolvimento e à compreensão dos processos físicos globais que afetam a Terra. Por intermédio da utilização de informações por satélite, é possível adquirir uma vasta quantidade de dados geográficos disponíveis em conjunto com os SIG, viabilizando um auxílio na interpretação de fenômenos.

SIG é um sistema integrado de *hardware* e *software* capaz de capturar, armazenar, manipular e analisar informações georreferenciadas com a finalidade de auxiliar a gestão orientada para o desenvolvimento e os processos de tomada de decisão. Aliados ao sensoriamento remoto, tais sistemas abrangeram uma vasta gama de aplicações na agricultura e nos diversos tipos de ambientes.

À vista disso, diversas pesquisas concentram-se em áreas de vegetação. Nesse sentido, são utilizados os dados da missão Sentinel para detectar as mudanças da paisagem na área selecionada, evidenciando fatores naturais e antrópicos. A partir da proposta de estudo, são avaliadas as dinâmicas da vegetação, com destaque para o mangue, a ocorrência de desmatamento e os processos de erosão marinha.

A importância de trabalhar com o intervalo de amostragem temporal de dados Sentinel deve-se à periodicidade, por oportunizar a geração de séries temporais anuais com cobertura de dez dias para o produto Sentinel-1 (radar) e cinco para Sentinel-2 (óptico), com abordagens de filtragem e composição à geração de produtos temáticos. Já as mudanças no uso e na cobertura da terra são estudadas em conjunto, precipuamente em estudos envolvendo sensoriamento remoto.

Portanto, aliado ao conhecimento de que as zonas costeiras são áreas de progradação, onde ocorre acumulação de sedimentos quartzosos, siltosos e argilosos, juntamente com os processos da dinâmica dos ventos alísio de Nordeste e à deriva litorânea, e por conseguinte, esses fatores contribuem para a expansão do mangue (SILVA, 2013).

Embora haja condicionantes oceanográficos que interferem na dinâmica natural da área em epígrafe, a exemplo da diminuição do aporte de sedimentos e erosão marinha, e ação antrópica por meio de desmatamentos, contaminantes químicos ou radiativos, tais fatores intervêm na dinâmica da vegetação.

2.3 Radar, RAR, SAR e ótico

Radar é uma sigla que significa *Radio Detection and Ranging* (Detecção e Telemetria por Rádio). Em outras palavras, trata-se da utilização da técnica que emite radiação micro-ondas como sinal de medição entre o sensor e o alvo (ESA, 2014a). As imagens de radar são classificadas em Radar de Abertura Real (RAR) e Radar de Abertura Sintética (SAR).

O RAR transmite ondas de rádio em um ângulo estreito na direção da faixa, em ângulos retos para a direção do voo, e recebe a retrodifusão dos alvos que serão transformados em uma imagem de radar. As imagens RAR são pobres em resolução, para a qual se exige uma antena cada vez maior, visando a melhorar essa resolução – para 25 metros, por exemplo, seria necessária uma antena de um quilometro de diâmetro (POÇAS, 2011; NASDA, 1999).

Em face dessa realidade, a solução para o alcance de melhores resoluções é a utilização de imagens SAR, que lança mão de um método tecnologicamente mais avançado por meio do qual há a aquisição de imagens de radar em alta resolução a grandes distâncias, via satélite (POÇAS, 2011; ESA, 2014b).

3 ÁREA DE ESTUDO

Selecionou-se uma área de estudo que se compatibiliza com a intersecção, com a sobreposição dos dois tipos de imagens Sentinel (Radar) 1A e (Ótica) 2A. A seleção compreende uma área de 6.820,63 km², sendo 5.965,10 km² continental e 855,53 km² oceânica, situadas no quadrante 42°7'50,461"W, 2°43'33,236"S e 41°20'11,715"W, 3°25'26,748"S (Figura 3), abrangendo as seguintes microrregiões: Lenções Maranhenses (0,10%); Baixo Parnaíba piauiense (0,68%); litoral de Camocim e Acaraú (1,89%); Baixo Parnaíba maranhense (28,05%); e litoral piauiense (69,28%).

A geologia da região é caracterizada por uma compartimentação em sete períodos geológicos, sendo o mais antigo o Sideriano, da Era Proterozoica, com destaque para os ortognaisses de natureza tonalítica-trondhjemítica-granodiorítica, associados a migmatitos. Em seguida, no Ediacarano, concebe-se a formação Suíte Intrusiva Chaval, com a presença de granodioritos e quartzo-sienitos (CPRM, 2003).

Na Era Paleozoica, dois períodos podem ser enfatizados: o Devoniano, com a formação Pimenteiras, constituída por arenitos, siltitos e folhelhos; e o Siluriano, que integra o Grupo Serra Grande, formado por conglomerados, arenitos e intercalações de siltitos e folhelhos, além de ambientes fluviais entrelaçados e marinho raso (CPRM, 2003).

O período Terciário é marcado pela formação do grupo Barreiras, constituído por arenitos e conglomerados, com intercalações de siltitos e argilitos (CPRM, 2003), sob condições de clima semiárido sujeito a chuvas concentradas e torrenciais – o que deu origem a depósitos de leques aluviais coalescentes (GHIGNONE, 1979 apud SUGUIO *et al.*, 1985).

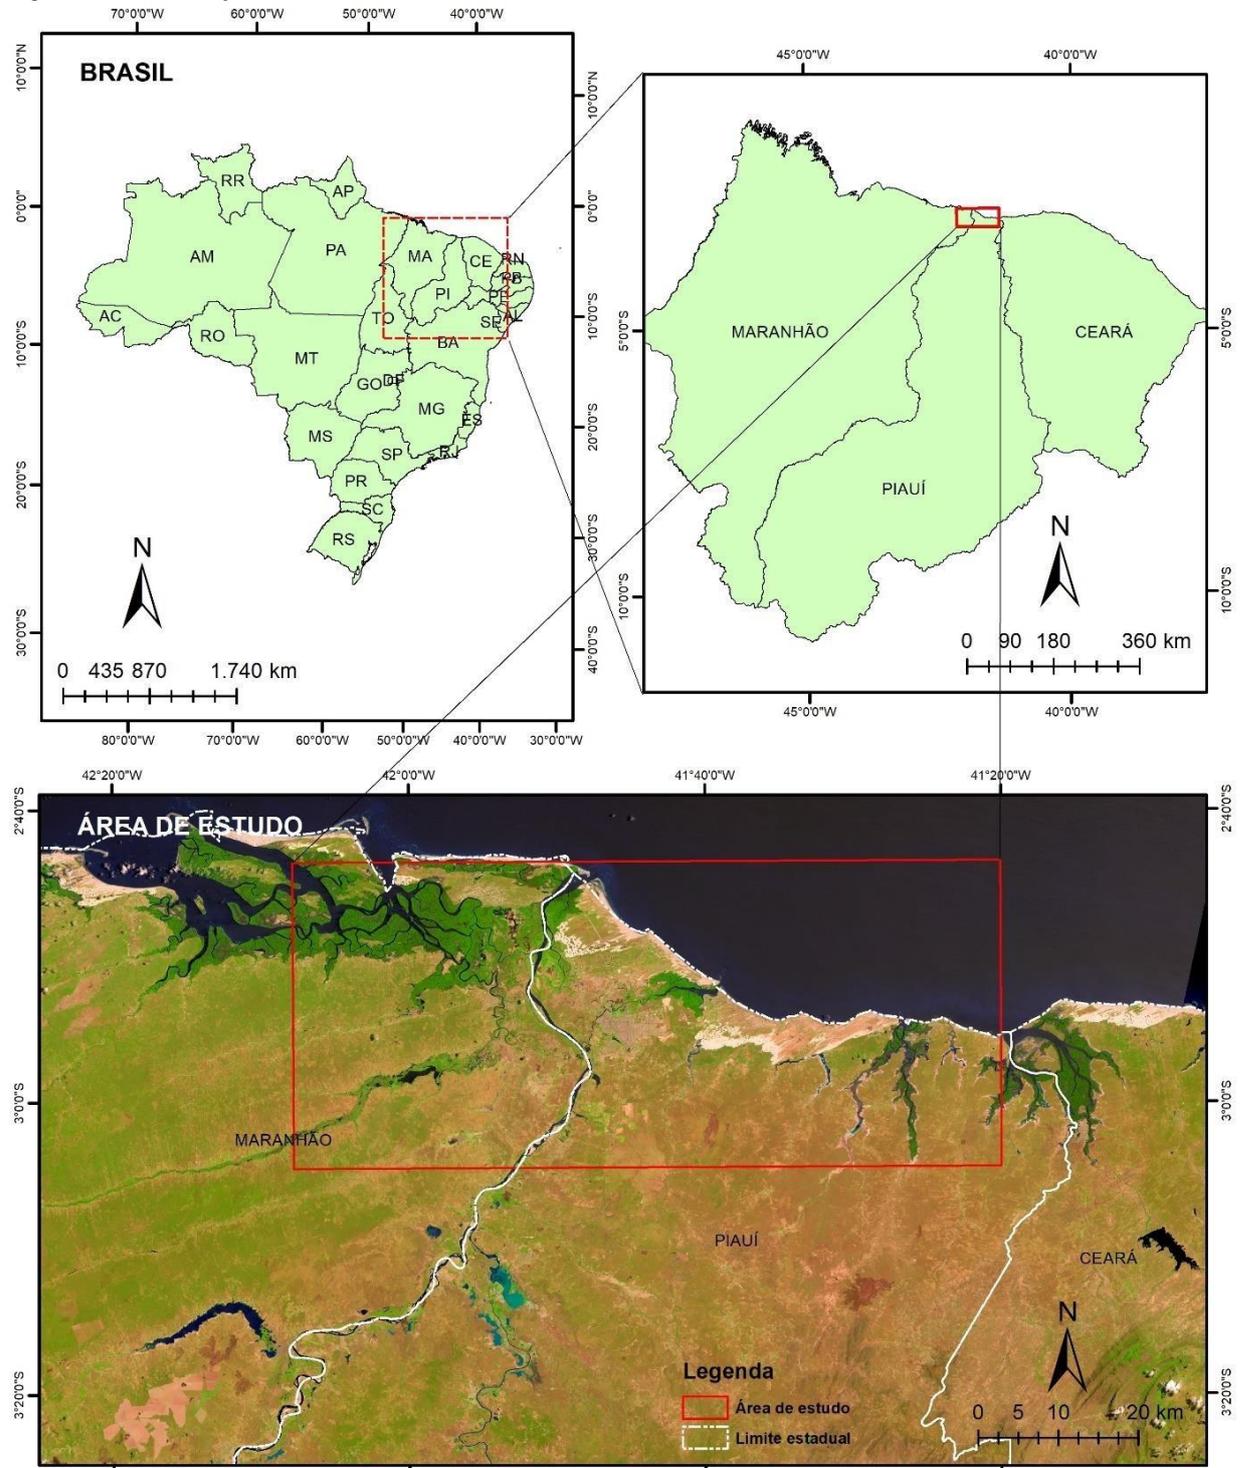
No período Pleistoceno, sobrelevam-se as paleodunas, formadas por areias selecionadas, quartzosas ou quartzo-feldspáticas, ambientes eólicos-litorâneos e depósitos de mangue constituídos de areia, silte, argila e material orgânico (CPRM, 2003).

Por fim, o período Holoceno da Era Cenozoica é representado pelos depósitos aluvionares constituídos por areias e cascalhos, apresentando certos níveis de argilas e depósitos litorâneos caracterizados pela presença de areias finas a grossas, e dunas móveis.

Quanto à hidrografia, o principal rio, o Parnaíba, nasce na Serra da Tabatinga e Chapada das Mangabeiras, onde se localiza o Parque Nacional das Nascentes do Rio Parnaíba, abrangendo os municípios de Alto Parnaíba (MA); Barreiras do Piauí, Corrente, Gilbués e São Gonçalo do Gurguéia (PI); Formosa do Rio Preto (BA); São Félix do Tocantins, Mateiros e Lizarda (TO). As nascentes são resultantes dos afloramentos dos cursos dos rios Lontras, Curriola e Água Quente, que unidos formam o Parnaíba, um rio perene em toda sua extensão,

de 1.400 km, aproximadamente, cuja bacia hidrográfica percorre uma área de 344.122 km² (IBGE, 1996).

Figura 3 – Localização da área de estudo



Fonte: IBGE (2022); CPRM (2018); MMA (2018).

Além do rio Parnaíba, cuja foz é um delta e seu sistema de canais fluviais, compreende os estuários dos rios Timonha e Ubatuba, onde na dinâmica dos baixos vales ocorrem planícies fluvio-marinhas recobertas com florestas de mangue, patenteando a influência das marés.

A geomorfologia da área é bastante diversificada, compondo uma paisagem formada por planície deltaica, estuários, praias, terraços fluviais, planícies de maré (fluvio-marinha) ou depósitos de mangue, tabuleiros litorâneos, planaltos, dunas. Praticamente a faixa litorânea de todo o período Quaternário é representada por areias quartzosas se sobrepondo à formação Barreiras.

Os depósitos de mangues ocorreram em virtude da deposição de sedimentos fluvio-marinhos nas planícies de maré, desenvolvendo extensas florestas de mangue, como resultado de um processo de acumulação fluvio-marinha, com vegetação altamente especializada em substrato essencialmente argiloso, sujeito à inundação pelas marés (AGUIAR, 2004).

O aporte de sedimentos somados à localização de proximidade à Zona de Convergência Intertropical com os ventos alísios de Nordeste é responsável pelos extensos campos de dunas. Assim, a influência fluvial pode ser caracterizada não só pela presença de sedimentos quartzosos carreados pelos rios, mas também pela presença das planícies de maré, sendo singularizada por amplas áreas de florestas de mangue (SILVA, 2013).

Tais formações são provenientes de uma periodicidade climática dos ventos alísios de Nordeste. Essa dinâmica climática, somada ao aporte de areias quartzosas e sedimentos silteosos e argilosos, juntamente com a dinâmica oceanográfica, é responsável pelas formações geomorfológicas.

Por sinal, a caracterização dos principais solos que compõem a área foi conduzida com base em informações contidas nos levantamentos realizados pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA, 2006), e em nível exploratório, em trabalhos de reconhecimento em campo. Nessa perspectiva, as principais classes de solos são: Neossolos Quartzarênicos; Solos Indiscriminados de Mangue; Gleissolos; Planossolos; Latossolo Amarelo; Argissolos Vermelho-Amarelos; Argissolo Amarelo Distrófico; Planossolo Háptico Eutrófico.

A área é submetida aos principais sistemas sinóticos dessa região, a Zona de Convergência Intertropical (ZCIT), que representa a convergência dos ventos alísios do hemisfério Norte e do hemisfério Sul, verificada ao longo do equador térmico da terra (CEPRO, 1996).

Na prática, a influência da ZCIT traduz-se em chuvas intensas e relativamente regulares, sobretudo nos meses de março, com 357 mm, e abril, com 336 mm – quando se verificam as máximas de precipitação. Entre os meses de agosto e novembro, as precipitações variam de 2mm a 8mm (SILVA, 2013; EMBRAPA, 2006).

Outros sistemas produtores de tempo local abrangem a região como um todo, quais sejam: Frentes Frias; Vórtice Ciclônico de Altos Níveis (VCAN); Linhas de Instabilidade (LI); Complexo Convectivo de Mesoescala (CCM); Ondas de Leste (OL); e brisas marítimas e terrestres (SILVA, 2013).

Entre os meses de novembro e janeiro, há penetração de frentes frias nas latitudes tropicais, acarretando chuvas. Nos meses de janeiro a fevereiro, os VCANs adentram a região Nordeste, sendo formados no Oceano Atlântico no período de novembro a março (GAN; KOUSKY, 1982).

Quanto às brisas marítimas e terrestres, por integrarem uma área que sofre atuação dos ventos alísios de Nordeste, são intensificadas, e a terrestre é praticamente nula – o que se pode constatar pelo grande aporte de areias quartzosas em forma de extensas dunas barcanoides transportadas pelo vento (SILVA, 2013).

Os dados climáticos foram coletados a partir da Embrapa (2006), tendo como base de informações a estação meteorológica de Parnaíba, única em funcionamento. As condições térmicas apresentam-se estáveis, com variedade média mensal mínima ao longo do ano. Considerando-se os índices médios de temperatura do ar (° C), variam de 25° C a 27,6° C, configurando a característica de pequena amplitude térmica anual das localidades tropicais como um todo.

As unidades fitogeográficas vislumbradas, em consonância com os trabalhos do Instituto Brasileiro de Geografia e Estatística (IBGE, 1996), são elencadas a seguir: vegetação pioneira psamófila; vegetação subperenifólia; mata ciliar de várzeas; vegetação de tabuleiros; e florestas de mangue. A vegetação pioneira psamófila apresenta-se como um estrato rasteiro ou gramíneo-herbáceo, localizando-se nos setores de alta praia, sobre dunas semifixas e em depressões interdunares, e suas espécies são adaptadas ao ambiente dos terrenos arenosos e salinos.

A vegetação subperenifólia de dunas apresenta espécies de maior porte. As espécies arbóreas ocupam as encostas semiedafisadas de sotavento; já as arbustivas ocupam as vertentes de barlavento, onde é menor a influência das ações eólicas.

As florestas de mangue aludem à cobertura vegetal típica dos ambientes flúvio-marinhos, as planícies de maré. Trata-se de ambiente lodoso, de cores escuras, parcial ou totalmente submersas. Os *húmus* que aí se formam contribuem para ativar as fermentações. A vegetação local é muito densa e de porte exuberante, especialmente nas ilhas que compõem a região deltaica.

As espécies que integram o ecossistema dos manguezais (aqui entendido como florestas de mangue) emitem raízes adventícias e têm diferentes portes de troncos e de ramos. Suas principais espécies são o *Rhizophora mangue* – mangue vermelho ou sapateiro; *Laguncularia racemosa* – mangue branco ou rajadinho; e *Conocarpus erectus* – mangue de botão ou de bolota (SILVA, 2013).

A mata ciliar de várzeas ocupa as áreas de planícies fluviais e de planícies-lacustres, além de áreas de ambientes inundáveis, a exemplo do que se percebe na área da Ilha Grande de Santa Isabel, no Piauí, e em setores de relevos deprimidos de fundos argilosos do litoral ocidental do Ceará, nos municípios de Chaval e Barraquinha. Dentre as espécies típicas da Mata de Várzeas, a que tem maior utilização é a *Copernicia prunifera* – carnaúba (SILVA, 2013).

A vegetação de tabuleiro, como o próprio nome pressupõe, ocupa os setores pré-litorâneos da região, em solos derivados de sedimentos da formação Barreiras. Trata-se de um complexo florístico que inclui espécies de matas, Caatingas, Cerrados e cerradões. Fisionomicamente, apresenta a predominância de um estrato arbustivo-arbóreo.

Quanto ao processo de ocupação, povoamento e produção do espaço geográfico nessa área litorânea do Maranhão, Piauí e Ceará, é necessário sublinhar que desde o período anterior à chegada dos europeus à América, os registros revelam que os navegantes que chegaram a essa região tiveram contato com indígenas – os primeiros habitantes – até o desenvolvimento da pecuária, que se interiorizou no sertão nordestino. Segundo esses registros, os índios Tremembés foram os primeiros habitantes da região litorânea, no Maranhão, Piauí e Ceará, desde o século XIII (NUNES, 1975; BORGES, 2004).

Com efeito, o processo de ocupação dessa área foi totalmente diferenciado do restante do Nordeste do Brasil, de modo que sua dinâmica se processa sob duas vertentes principais: uma corresponde ao desenvolvimento do comércio de exportação da carne bovina, que surgiu no século XVII como atividade complementar ao complexo monocultor da plantação açucareira, dominando a faixa litorânea a partir do Recôncavo Baiano até Pernambuco.

Decerto, a colonização dessa faixa litorânea pode ser atribuída a uma repercussão dos “caminhos do gado” pelos sertões do interior do Piauí e Ceará, ocorrendo o seu processo de ocupação do continente para o litoral (GUERRA, 2009).

A outra vertente alusiva ao crescimento populacional, que corresponde ao estado do Maranhão, foi a presença da igreja, por intermédio de seus evangelizadores, basicamente jesuítas. Nesse contexto, os aldeamentos indígenas transformados em missões jesuíticas na antiga Província do Grão-Pará tiveram papel relevante na exploração da natureza pré-amazônica (BRASIL, 1998).

Destarte, o conhecimento secular dos índios sobre a floresta foi repassado aos jesuítas, que transformaram o extrativismo das plantas de espécies amazônicas em um dos mais rentáveis negócios do período colonial. Dessa maneira, a vocação extrativista e agrária dessa parte do litoral do Maranhão foi condicionada, em suas origens, por uma forma de colonização diferente dos “caminhos do gado” e de sua área de influência.

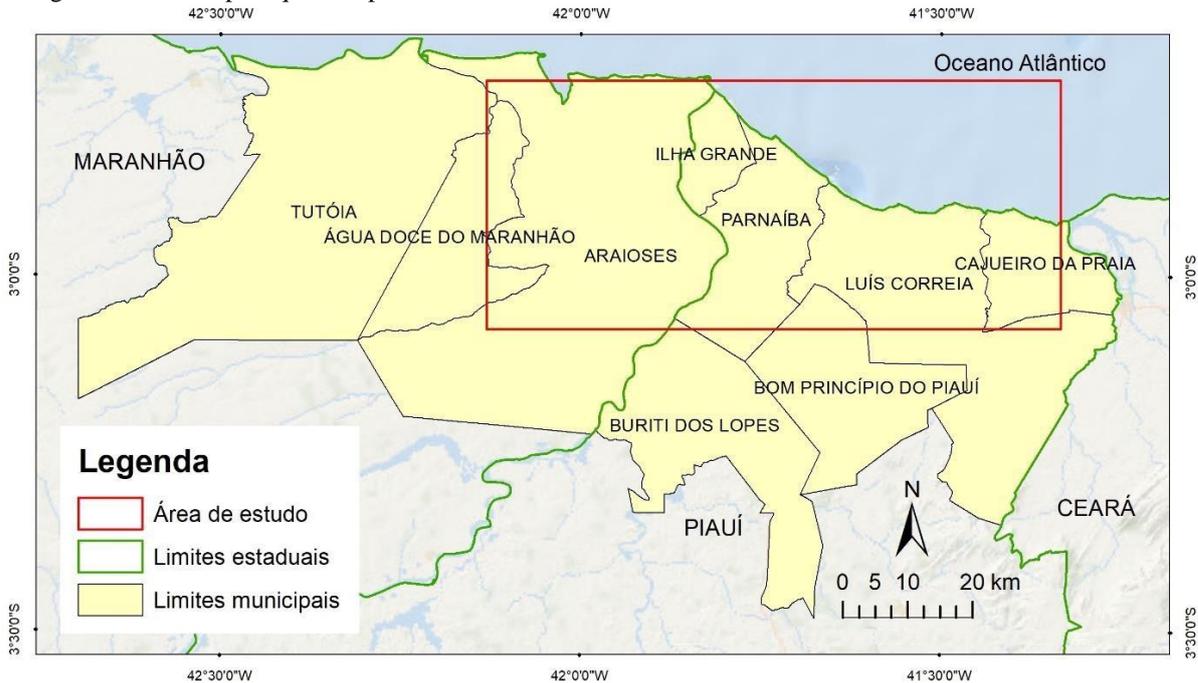
A população dos municípios dessa região litorânea (Figura 4), em 1980, era de 326.807 habitantes, atingindo, em 2015, o quantitativo de 464.321 habitantes (IBGE, 2018), perfazendo uma taxa de crescimento anual de 1,035% (Tabela 1). Cabe salientar que o incremento populacional dos últimos anos é resultado do crescimento natural e dos investimentos no setor turístico, os quais estimularam a imigração.

Tabela 1 – População residente, por ano, segundo e por município (1980-2010)

Município	1980	1985	1990	1995	2000	2005	2010	2015
Água Doce do Maranhão-MA	-	-	-	-	9.703	9.807	11.581	12.257
Araioses-MA	44.351	44.206	44.061	45.159	34.906	35.162	42.505	45.252
Magalhães de Almeida-MA	11.240	11.356	11.470	11.866	13.021	13.977	17.587	19.266
Tutóia-MA	39.610	41.292	42.949	44.991	37.728	44.734	52.788	57.253
Bom Princípio do Piauí-PI	-	-	-	5.550	4.625	4.237	5.304	5.493
Buriti dos Lopes-PI	25.823	28.175	30.491	32.084	18.598	18.414	19.074	19.411
Cajueiro da Praia-PI	-	-	-	-	6.122	6.155	7.163	7.450
Caxingó-PI	-	-	-	-	4.147	4.956	5.039	5.275
Cocal-PI	24.308	25.523	26.725	28.040	24.150	25.023	26.036	27.224
Ilha Grande-PI	-	-	-	-	7.890	8.537	8.914	9.209
Joaquim Pires-PI	14.022	14.297	14.569	15.065	13.076	13.266	13.817	14.080
Luís Correia-PI	25.626	27.079	28.519	29.517	24.253	25.459	28.406	29.547
Murici dos Portelas-PI	-	-	-	-	6.375	6.449	8.464	8.907
Parnaíba-PI	102.174	113.875	125.398	131.204	132.282	141.938	145.705	149.770
Granja-CE	39.653	40.495	41.320	42.760	48.484	52.858	52.645	53.927
TOTAL	326.807	346.298	365.502	386.236	385.360	410.972	445.028	464.321

Fonte: IBGE (1980-2015).

Figura 4 – Municípios que compõem a área de estudo



Fonte: IBGE (2015).

Em 2015, o município mais populoso era Parnaíba, com uma população de 149.770 habitantes. Sua densidade demográfica também foi a maior da área, com 343,02 hab/km² – índice acima da densidade demográfica de toda a região litorânea, que era 35,35 hab/km². Por seu turno, o município com menor densidade populacional situava-se no centro da área litorânea: trata-se de Bom Princípio do Piauí, com 10,50 hab/km².

Essa região litorânea apresenta taxas de densidade demográfica elevadas. Sem embargo, os municípios que integram o Maranhão representam as menores taxas. Ademais, notabiliza-se que os municípios maranhenses sofreram um processo de povoamento diferenciado, como visto outrora.

No mesmo período, de 2005 a 2010, os municípios apresentaram o maior crescimento populacional, com taxa acumulada de 8,29%. Não obstante, nos anos de 1995 a 2000, atingiram uma redução populacional de 0,23%, como resultado das perdas territoriais pelas quais passaram alguns municípios.

4 MATERIAIS E MÉTODOS

A partir da análise ancorada nos fundamentos teórico-conceituais e nas investigações empíricas, elencam-se neste capítulo os materiais e métodos que atendem de forma mais adequada a proposta deste estudo, com a finalidade de obter resultados satisfatórios para alcançar os objetivos da pesquisa.

Nesse diapasão, os métodos para explicar as inter-relações e os processos ora descritos estão designados na sequência.

4.1 Pesquisa bibliográfica e fontes de pesquisa

Como parte básica e fundamental de todo trabalho acadêmico, a exploração do referencial teórico-conceitual se realiza por meio de pesquisas bibliográficas em livros, teses e revistas científicas. Tal levantamento leva em conta, além do tema proposto, a relevância da pesquisa, com base em fator de impacto igual ou superior a um nos periódicos.

Para cumprir o objetivo final, pesquisam-se bases de dados oficiais, conforme segue: para a coleta de imagens e composição de mapas, da EMBRAPA, do Instituto Nacional de Pesquisas Espaciais (INPE), da Global Visualization Viewer (GloVis), da U. S. Geological Survey (USGS), e da National Aeronautics and Space Administration (NASA); visando ao levantamento de dados estatísticos e do meio físico, da Diretoria de Hidrografia e Navegação (DHN), da Marinha do Brasil, da Comissão Oceanográfica Intergovernamental (COI), do Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMET), da Companhia de Pesquisa de Recursos Minerais (CPRM), e da Agência Nacional de Águas (ANA).

A análise metodológica proposta, tanto em termos de resolução temporal quanto de dados de sensores, incluirá também dados de atividade econômica e populacional da base de dados do IBGE.

4.2 Séries temporais como aporte para o monitoramento

Um conjunto de observações cronológicas é composto por um número específico de registros – cada um datado em um momento determinado. Esses registros formam uma série temporal identificada por T_0 , e são resultado de observações adquiridas em intervalos de tempo fixos. As séries temporais contínuas são obtidas quando as observações são coletadas sem interrupções, durante certo período. Assim, a representação de uma série temporal pode ser representada por $T = [0, 1]$. Destarte, $x(t)$, a observação específica x é identificada por t ,

indicando que as observações foram registradas de maneira contínua (BROCKWELL; DAVIS, 1991).

Essa proposta de pesquisa visa a utilizar séries temporais para detectar, identificar, mapear, monitorar e analisar mudanças em ecossistemas, a partir de técnicas derivadas dos dados do sensor Sentinel.

De acordo com Coppin *et al.* (2004), trabalhos nessa área têm abordado três aspectos principais: a análise de mudanças bienais; a análise das trajetórias temporais; e a discussão sobre o tempo de aquisição de imagens para estabelecer o comprimento de intervalo de mudança. Adicionalmente, o protocolo de pré-processamento será revisto para detectar alterações e estabelecer uma ligação entre os dados de sensoriamento remoto e os fenômenos biofísicos, permitindo inferências.

A utilização de séries temporais possibilita a criação do Índice de Vegetação, que é crucial para a análise da cobertura da terra ao longo de um período estabelecido (COUTO JÚNIOR, 2012). Além disso, permite analisar a distinção fenológica da vegetação e registrar as mudanças no uso e na cobertura do solo (WARDLOW *et al.*, 2007; VERBESSELT *et al.*, 2010). Como cada imagem tem um registro temporal, as possibilidades de análise são inúmeras, e uma delas é a detecção de mudanças.

Na década de 1980 e início de 1990, a utilização de séries temporais a partir de imagens de satélite para detecção de mudanças era muito cara, lenta e cansativa (FUNG; LEDREW, 1987 apud SOARES; HOFFER, 1996).

No entanto, com o avanço da tecnologia e novos métodos, ela tornou-se de extrema importância, usando recursos automatizados cada vez mais eficientes. Por conseguinte, a detecção de mudanças tem-se tornado objeto de interesse em diversas áreas da ciência.

A presente pesquisa avalia o potencial de dados Sentinel-1 da banda C e Sentinel-2 sobre a zona costeira que abrange os estados do Maranhão, Piauí e Ceará. Dados SAR possuem ruído que dificulta sua análise e interpretação. Para suplantiar essas dificuldades, utilizou-se para detecção de manguezal o *Probability Density Components Analysis-Series Time* (PDCA-ST), em 33 cenas nas polarizações VV e VH para filtragem do ruído.

O Sentinel-1 é um sensor de satélite de Radar de Abertura Sintética (SAR) desenvolvido pela Agência Espacial Europeia (ESA) para fornecer imagens contínuas para qualquer clima, dia e noite, em uma variedade de aplicações. Nesse ensejo, opera na frequência da banda C e oferece uma resolução espacial que varia de 5 a 40 metros, dependendo do modo de imagem.

4.3 Aquisição das imagens do sensor Sentinel-1

Para adquirir imagens do Sentinel-1, várias técnicas e etapas de processamento são necessárias. Primeiramente, é necessária a seleção do modo de imagem apropriado e da área de interesse. O sensor Sentinel-1 dispõe três modos de imagem diferentes: *Interferométrico Wide Swath* (IW), *Extra Wide Swath* (EW) e *Stripmap* (SM). A presente pesquisa utiliza as imagens IW, cujo modo fornece uma largura de faixa de até 250 km, oferecendo uma resolução espacial de 5x20 metros na polarização dupla (VV / VH) e 10x20 metros no modo de polarização única (HH / HV). Esse modo é adequado para aplicações como monitoramento oceânico e costeiro, monitoramento de deformação da terra e mapeamento de áreas urbanas (UNIÃO EUROPEIA, 2018).

Após a seleção do modo, a aquisição de dados foi realizada por meio do *Copernicus Open Access Hub*. Os dados são armazenados em um formato *Ground Range Detected* (GRD), Nível 1, que inclui informações de amplitude e fase.

Depois de adquirir os dados, várias etapas de processamento foram necessárias para extrair informações úteis, as quais envolvem calibração radiométrica, filtragem do ruído, correção de terreno e geocodificação. A calibração radiométrica é necessária para converter a amplitude do sinal do radar em coeficiente de retroespalhamento, que é proporcional à refletividade da superfície. A filtragem do ruído é empregada para reduzi-lo – ele é causado pela interferência de ondas de radar coerentes. A correção do terreno é necessária para remover os efeitos da topografia no sinal do radar. Finalmente, a geocodificação é o processo de projetar a imagem do radar em um sistema de coordenadas geográficas.

O sensor Sentinel-2 é uma ferramenta valiosa para adquirir imagens ópticas de alta resolução da superfície da Terra. Ele é capaz de fornecer dados multiespectrais em 13 bandas espectrais, permitindo a detecção e o monitoramento de várias características da superfície terrestre.

4.4 Aquisição das imagens do sensor Sentinel-2

A aquisição de imagens do Sentinel-2 envolve vários fatores, incluindo o tempo de revisão, a resolução espacial e a cobertura de nuvens. O Sentinel-2 tem um tempo de revisão de cinco dias no Equador, podendo ser reduzido para 2-3 dias, com a combinação de dois satélites. A resolução espacial das imagens do Sentinel-2 varia de 10 a 60 metros, dependendo da banda espectral, com a maior resolução na banda pancromática. A cobertura de nuvens pode afetar significativamente a aquisição de imagens, pois as nuvens podem obscurecer a superfície da

Terra. No entanto, imagens sem nuvem podem ser obtidas usando os algoritmos de triagem em nuvem Sentinel-2 (DRUSCH *et al.*, 2012).

O Sentinel-2 é um sistema de sensores baseado em dois satélites que adquirem imagens ópticas multiespectrais de alta resolução da superfície da Terra. Um dos principais recursos das imagens do Sentinel-2 é sua alta resolução espacial, pois seu sensor possui uma gama de resoluções espaciais, de 10 a 60 metros, com a maior resolução na faixa pancromática.

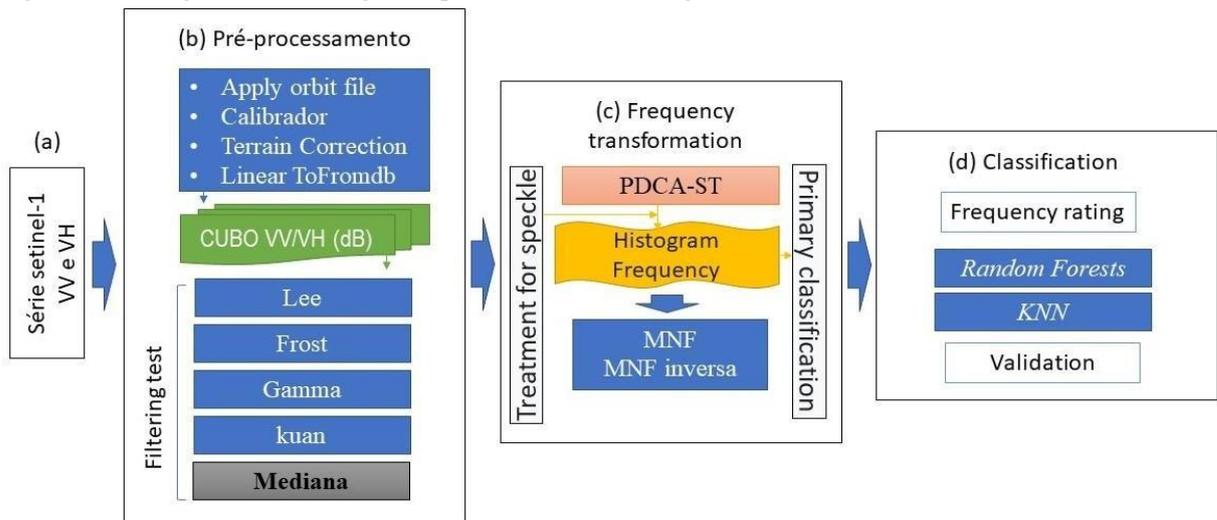
As imagens do Sentinel-2 também têm ampla faixa espectral, cobrindo 13 bandas espectrais nas regiões visíveis, infravermelhas próximas e infravermelhas curtas do espectro eletromagnético. Essa faixa espectral permite a detecção e caracterização de várias características da superfície da Terra, incluindo vegetação, corpos d'água e áreas urbanas.

4.5 Processamento das imagens Sentinel-1

O processamento das imagens Sentinel-1 é um passo importante para garantir a qualidade e a utilidade desses dados para posterior classificação. As imagens Sentinel-1 foram processadas para corrigir distorções causadas por fatores como inclinação do satélite, ondulações da superfície do mar e outros efeitos atmosféricos. Além disso, as imagens são processadas para filtrar o ruído e melhorar a resolução espacial.

A presente metodologia foi subdividida nas seguintes etapas, conforme fluxograma (Figura 5): seleção e aquisição da série de imagens SAR do Sentinel-1; pré-processamento e filtragens para suavização do ruído; construção do cubo tridimensional; tratamento do ruído por histograma de frequência; classificação de imagem e acurácia.

Figura 5 – Fluxograma metodológico do processamento de imagens



Fonte: Elaboração Própria (2022).

4.5.1.1 Dados do Sentinel-1

A presente pesquisa utilizou os dados Sentinel-1, no modo *Interferometric Wide Swath* (IW), produzidos como *Ground Range Detected High Resolution* (GRDH) (Tabela 2). A missão Sentinel-1 possui a banda C, com uma frequência central de 5,405 GHz, e resolução de 10 m (ESA, 2019). Em relação aos antigos sensores espaciais de banda C, o Sentinel-1 oferece melhor calibração radiométrica e maior cobertura espacial e temporal (TORRES *et al.*, 2012).

O período de tempo analisado na pesquisa foi de 8 de abril de 2017 a 21 de maio de 2018, alcançando 33 imagens para cada polarização Vertical-Vertical (VV), e Vertical-Horizontal (VH). Ambas as polarizações VV e VH são utilizadas para monitorar as florestas de mangue (ARGAMOSA *et al.*, 2018; CASTILLO *et al.*, 2017; CHEN *et al.*, 2017; NAVARRO *et al.*, 2019).

4.5.1.2 Pré-processamento

Para a realização do pré-processamento dos dados Sentinel-1, lançou-se mão do *software* SNAP 6.0, aplicando a correção de órbita, calibração, correção do terreno e a conversão de dados lineares para dB (decibéis).

Tabela 2 – Especificações do modo IW imagens Sentinel 1

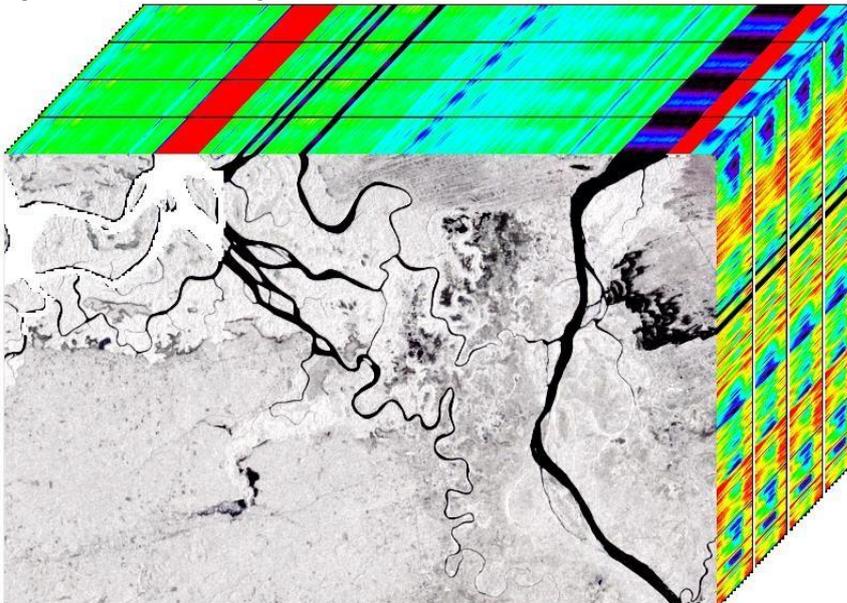
Especificação	Valor
Distância da amostra GRDH	10 m
Faixa de ângulo de incidência nominal	31 ° a 46 °
Largura da faixa	250 km
Precisão radiométrica	1 dB (3σ)
Estabilidade radiométrica	0,5 dB (3σ)

Fonte: COPERNICUS, 2018

4.5.1.3 Construção e filtragem de cubos tridimensionais

O cubo de empilhamento de imagens em 3D foi composto pelas imagens Sentinel-1 (Figura 6), construído de três cubos, sendo dois deles com 33 imagens, cada – um VV e outro VH; e um cubo contendo 66 imagens, do período de 8 de abril de 2017 a 21 de maio de 2018, intercalando imagens de polarização VV e VH com os testes realizados nos diferentes filtros, de modo que os melhores resultados partiram do terceiro cubo VV/VH. Um dos principais procedimentos no pré-processamento corresponde à suavização do *speckle* por filtragem. Na presente pesquisa, empregaram-se os filtros: Lee (LEE, 1983; LEE *et al.*, 2009); Frost (FROST *et al.*, 1982); Gamma (DE VRIES, 1991; DE VRIES, B; PRINCIPE, 1992); Kuan (KUAN *et al.*, 1985); e mediana (TUKEY, 1977; HUANG, YANG, TANG, 1979) – esse último trouxe melhores resultados, com o cubo de 66 imagens e dados intercalados VV/VH.

Figura 6 – Cubo de imagens 3D



Fonte: Elaboração Própria (2022).

4.5.1.4 Probability Density Components Analysis-Series Time (PDCA-ST)

O PDCA-ST realiza uma combinação entre a densidade de probabilidade e filtragem, calculando o histograma de frequência, que é um resumo da distribuição temporal do retroespalhamento na imagem para uma janela móvel, distribuindo o valor de cada classe em uma imagem específica (CARVALHO JÚNIOR, *et al.*, 2014).

Nessa continuidade, gera-se uma sequência de imagens em que o número de imagem é igual ao número de histogramas, dividindo cada classe em uma frequência (CARVALHO JÚNIOR *et al.*, 2014). Dessa forma, em um determinado intervalo de classe, será evidenciada uma ocorrência que é a classificação.

O método PDCA consiste na utilização do número de classes presentes no histograma e no tamanho da janela (MACIEL, 2012). O número de classes deve ser compatibilizado com o tamanho da janela, então a distribuição dos *pixels* permitirá uma aglutinação nos intervalos das classes, estabelecendo uma curva de distribuição. O número de dados no histograma é o tamanho da janela que aplicada, deve ser avaliada de acordo com os dados e o objetivo da pesquisa (CARVALHO JÚNIOR *et al.*, 2014).

O procedimento usado é semelhante ao entendimento do cubo hiperespectral, em que é possível analisar o cubo PDCA – embora em uma linguagem não espectral – mas por meio da assinatura de densidade de probabilidade. Com isso, a densidade de probabilidade é um tratamento para o *speckle* (ruído). A análise de componentes de densidade de probabilidade é mostrada por meio do espectro, calculado para cada elemento espacial em uma imagem. A curva resultante deste processo descreve os diferentes alvos, as diferentes classes (CARVALHO JÚNIOR *et al.*, 2014).

4.5.1.5 Fração Mínima de Ruído (MNF)

A transformação da Fração Mínima de Ruído (MNF) é aplicada para suavização do ruído, extraindo os *pixels* extremos. É significativa, com espectros que exibem alguma correlação de bandas vizinhas, tendo como alvo selecionar os componentes de forma que se maximize a relação sinal-ruído. A MNF foi desenvolvida, inicialmente, para remover ruído de imagens multiespectrais (GREEN *et al.*, 1988), e posteriormente, para remover ruídos de séries temporais (ANDERLE; KIRBY, 2001). Neste estudo, após a realização do PDCA-ST, aplicou-se a MNF e MNF inversa.

A propósito, a MNF é um processo de duas etapas: inicialmente, os dados transformados apresentam o ruído, com variância unitária sem relação de banda com banda, seguida da

transformação dos componentes principais padrão onde os dados são atenuados (SATPATHY *et al.*, 2010; GAO *et al.*, 2013).

A transformação MNF, de caráter linear, é expressa pela seguinte equação:

$$Y_i(x) = a_i^T Z(x), i = 1 \dots, n; \text{No} \quad (1)$$

processamento da transformação MNF para a remoção do ruído, os dados passam por uma transformação direta, determinando quais bandas contêm as imagens coerentes. Posteriormente, realiza-se uma transformação MNF inversa, usando os dados estatísticos resultantes do primeiro processo – esses dados contêm a matriz de covariância do ruído, permitindo a identificação das bandas com melhor qualidade. A transformação MNF inversa das bandas MNF retoma à condição de dado original, suavizando as imagens com ruído.

4.5.1.6 Random Forests Classification

Na classificação das imagens, utilizou-se o *Random Forests* ou *Random Decision Forests* (HO, 1995; BREIMAN, 2001), disponível no *software* Abilius (uso não comercial), mediante linguagem C ++ (CARVALHO JÚNIOR *et al.*, 2011).

É um método de classificação supervisionada baseado em várias árvores de decisão, que são combinadas para obter uma predição com maior acurácia, estabelecendo uma separabilidade adequada entre classes. O *Random Forest* (RF) constrói várias árvores em distintos subespaços selecionados aleatoriamente. No processo, os subespaços são realizados para classificar de maneira complementar, podendo ser esses conjuntos de dados aprimorados. Assim, o resultado final é baseado na aceitação da maioria das árvores que constituem o conjunto da floresta (HO, 1998; BREIMAN, 2001; HU; YU; WANG, 2005; GAO *et al.*, 2015; LIAW; WIENER, 2002; DÍAZ-URIARTE; ANDRÉS, 2006).

Teoricamente, a fórmula matemática do algoritmo é definida por

$$\{h(x, \Theta_k, = 1, \dots)\} \quad (2)$$

onde Θ_k é o vetor arbitrário disposto em configuração igual em cada árvore (floresta) e no conjunto de árvore, é evidenciado um voto que, em sua maioria, é definida a classificação no valor “x” (BREIMAN, 2001).

Um aspecto importante a ser observado na classificação por RF, no que se refere ao conjunto de decisão, é que existe a possibilidade de erro ocasionado pela troca de amostras *out-of-bag* (OOB_t). Trata-se, portanto, de uma variável cujos valores são incluídos nas amostras usadas para construir a árvore de decisão (t). Assim, a estimativa de erro também é calculada ($errOOB_t$), e a *Variable Importance* (VI) de RF da variável X_j é calculada considerando as amostras *out-of-bag*. A acuidade da variável X_j é dada por

$$VI(X_j) = \frac{1}{ntree} \sum_t errOOB_t^j - errOOB_t \quad (3)$$

a soma de todas as árvores t da RF indica o *ntree*, número de árvores. Assim, a acuidade da variável é dada dividindo VI por cada variável pelo seu desvio-padrão (GENUER; POGGI; TULEAU-MALOT, 2010).

4.5.1.7 K Nearest Neighbor (KNN) Classification

O presente estudo utilizou as métricas do *K-Nearest Neighbor* (K-NN), tendo como finalidade destacar áreas com presença de mangues. O conceito da classificação empregando o modelo do vizinho mais próximo foi difundido por Fix e Hodges, na década de 1951, com o propósito de atribuir a regra de decisão em que uma amostra não classificada se relacione aos pontos de amostras classificadas.

Por sua vez, Steele e Redmond (2001), por exemplo, empregaram o método do K-NN no sensoriamento remoto visando a melhorar a classificação da cobertura do solo. O modelo de classificação k vizinho mais próximo é um método de aprendizagem baseado em distâncias, por isso é considerado como um classificador não paramétrico de aprendizagem supervisionada (FIX; HODGES, 1951; COVER; HART, 1967; ATKINSON; NASER, 2010).

Para esta pesquisa, foram utilizadas experimentalmente as distâncias de 5 a 15, e a métrica do valor k utilizada foi a Distância Euclidiana, conforme a expressão

$$D_E(p, q) = \sqrt{(p_1 - q_1)^2 + \dots + (p_n - q_n)^2} \quad (4)$$

$$= \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$$

onde a Distância Euclidiana é representada por: $p = (p_1, \dots, p_n)$ e $q = (q_1, \dots, q_n)$, que são os dois pontos n -dimensionais (FUKUNAGA; NARENDRA, 1975).

4.5.1.8 Análise de precisão

Lançou-se mão da Matriz de Confusão e do Índice Kappa. Nesta pesquisa, a classe manguezal em shapefile é usada como polígono de validação, coadunando dados do Ministério do Meio Ambiente (MMA). A Matriz de Confusão é expressa em uma matriz quadrada de números formada por colunas e linhas, sendo atribuídos os valores da classificação realizada e outra classificação, conjugando as respectivas categorias (CONGALTON; GREEN, 2009).

Isso posto, os pixels classificados corretamente estão na diagonal da matriz, e as outras partes fora da diagonal representam pixels erroneamente classificados. Assim, o número da precisão geral é calculado somando o número que corresponde aos valores classificados divididos pelo número total (CONGALTON; GREEN, 2009; HARRIS, 2019).

Tendo isso em vista, inúmeros trabalhos evidenciam a eficiência da matriz de confusão para validar seus dados (NINGTHOUJAM *et al.*, 2016; SON *et al.*, 2017; SILVA, 2018; DOSTÁLOVÁ *et al.*, 2018; SILVA *et al.*, 2019).

O índice Kappa compara os resultados da classificação com aquela resultante do processo realizado aleatoriamente na classificação de pixels. Fundamenta-se na proposição de que mesmo em uma classificação aleatória, parte dos pixels será classificada corretamente (COHEN, 1960).

Os valores são representados de zero a 1 (um), onde 1 corresponde 100% de conformidade, e 0 (zero), nenhuma concordância (JENSEN, 2005). A avaliação de concordância entre os dados de referência e os dados de classificação é determinada a partir dos dados da matriz de confusão (CONGALTON, GREEN, 2009), como se verifica na equação

$$Kappa = \frac{n \sum_i n_{ii} - \sum_i (n_{i+} n_{+i})}{n^2 - \sum_i (n_{i+} n_{+i})} \quad (5)$$

no qual n corresponde aos pixels classificados e comparados aos dados de referência; i é o número de classes, sendo n_{ii} o número de pixels da classe de referência i classificados com classe i , representando a diagonal da matriz; n_{+i} são os pixels classificados que compõem à classe i ; e n_{i+} são os pixels pertencentes à classe i (STEHMAN, 1996).

O Kappa é eficiente na validação dos processos de classificação (*e.g.* TWELE *et al.*, 2016; TORBICK *et al.*, 2017; TIAN *et al.*, 2018; DOSTÁLOVÁ *et al.*, 2018).

4.5 Processamento das imagens Sentinel-2

No Sentinel-2, o processamento inclui a correção de distorções atmosféricas e geométricas, bem como a fusão de diferentes bandas espectrais para gerar imagens coloridas e melhorar a capacidade de distinguir múltiplos tipos de cobertura do solo. Adicionalmente, os dados são processados para remover nuvens e sombras, o que é especialmente importante para aplicações de monitoramento ambiental e de recursos naturais. Em ambos os casos, o processamento das imagens Sentinel-1 e Sentinel-2 constituem uma etapa essencial para maximizar o valor desses dados para a pesquisa, a tomada de decisões e outras aplicações.

O recorte temporal desta pesquisa compreende um conjunto de sete imagens S-2, cada uma com nove bandas, abrangendo as seguintes datas (2017/04/12; 05/02; 07/26; 08/30; 09/04; 10/14; 11/18). Então, foram selecionadas as imagens com menor porcentagem de nuvens, com valor inferior a 5%. Dessa forma, realizaram-se os experimentos propostos nos objetivos.

Para esta pesquisa, empregaram-se imagens com resolução espacial de 20m, advindas de uma órbita circular, heliosíncrona, descendente e com resolução temporal de cinco dias. Cabe salientar que a periodicidade de cruzamento equatorial do sensor ocorre, aproximadamente, às 10h30, contribuindo para uma análise mais acurada dos dados, por tratar-se de uma área costeira com regime de marés de até 3m.

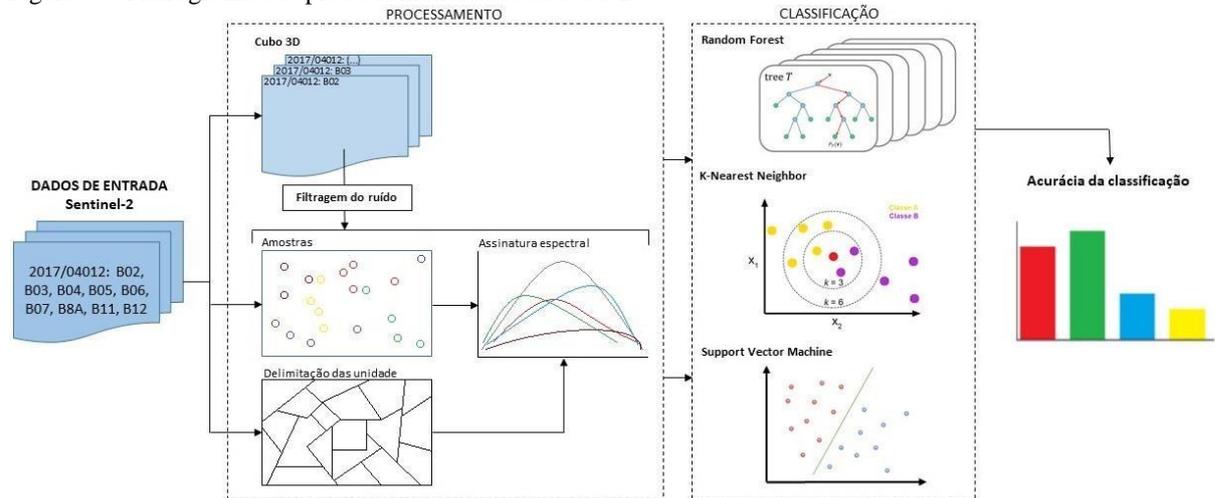
A missão S-2 da Agência Espacial Europeia caracteriza-se por dois satélites: 2^a, lançado em julho de 2015; e 2B, em março de 2017 – em órbitas circulares síncronas ao Sol a 786 km, com inclinação de 98,62°. Os produtos dessa constelação possuem treze bandas espectrais com três conjuntos de resolução, sendo quatro de 10m, seis de 20m e três de 60m (DUTRA; TAVARES; RIBEIRO, 2019; LI; ROY, 2017; MÜLLER-WILM, 2016; PAHLEVAN *et al.*, 2017).

O propósito principal da missão S-2 é permitir o monitoramento regular das mudanças globais no uso e na cobertura do solo. No entanto, a missão abre oportunidades para o mapeamento de constituintes da água próximos da superfície, incluindo as concentrações de sólidos suspensos totais e clorofila, e potencialmente a absorção por matéria orgânica dissolvida colorida em águas costeiras e interiores costeiras (ESA, 2018; PAHLEVAN *et al.*, 2017; SUDMANN *et al.*, 2019; TEODORO; BELTRÃO, 2018).

Nesta pesquisa, o tratamento dos dados óticos S-2 compõe-se de (Figura 7): pré-processamento dos dados de entrada; processamento, onde se realizam a confecção do cubo 3D

(in ENVI 5.1 softwares), a filtragem do ruído, a coleta das amostras de treinamento (ROIs) a delimitação das unidades, as assinaturas espectrais; a classificação Random Forest (RF) e K-Nearest Neighbor (KNN) (in Abilius software); já a acurácia foi realizada pela Matriz de Confusão e finalizado pelo teste McNemar.

Figura 7 – Fluxograma dos processamentos dos dados S-2



Fonte: Elaboração Própria (2022).

4.5.2.1 Pré-processamento

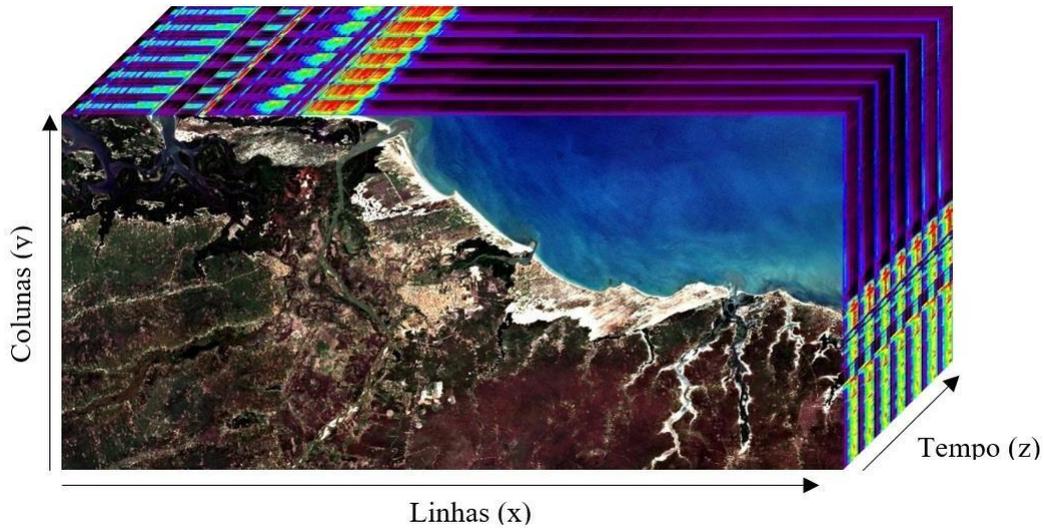
Nas imagens S-2 originais, são executadas a correção atmosférica, a correção do terreno e das nuvens cirros do topo da atmosfera pelo *software Sen2Cor* por *prompt* de comando. Ele gera imagens de refletância corrigidas também para os aerossóis, incluindo vapor da água, após essa etapa. Constitui, com isso, um conjunto organizado em sete tempos com nove bandas, cada, e pronto para processamento.

4.5.2.2 Processamento das imagens S-2

Construção do Cubo 3D

Para obter o perfil espectral, é necessária a construção do cubo 3D, que por intermédio das imagens de datas diferentes e sequenciais com respectivas bandas, gera o fator espectral em tempo e espaço. Assim, o cubo 3D representa os eixos “x” e “y”, que compreendem as coordenadas geográficas, o espaço; e o eixo “z”, o fator temporal (CARVALHO JÚNIOR *et al.*, 2008; CARVALHO; HERMUCHE; GUIMARÃES, 2006), como ilustra a Figura 8.

Figura 8 – Imagem do cubo 3D da série de bandas S-2



Fonte: Elaboração Própria (2022).

O cubo 3D é ordenado nas sequências de tempo dos dias. Esse procedimento permite a análise do comportamento espectral da vegetação a partir dos processos fotossintéticos ativos (CARVALHO JÚNIOR *et al.*, 2008).

Para a realização da filtragem, os dados foram redimensionados para 10m, proporcionando a normalização do sinal. Os dados do cubo multiespectral compreendem as seguintes características (Tabela 3):

Tabela 3 – Características das imagens do Cubo S-2

Resolução	Número	Nome	Comprimento de onda (nm)
10 m	B02	Blue	490
	B03	Green	560
	B04	Red	665
20 m	B05	Red Edge 1	705
	B06	Red Edge 2	740
	B07	Red Edge 3	783
	B8A	Red Edge 4	865
	B11	SWIR* 1	1610
B12	SWIR* 2	2190	

(*) luz infravermelha de onda curta.

Fonte: ESA, 2019.

Filtragem do ruído

Por tratar-se de uma área próxima à ZCIT e estar sob constante influência dos alísios de Nordeste, a região possui, na maior parte do ciclo climático, a presença de nuvens (SILVA, 2013).

As imagens óticas de cinco dias em tratamentos preliminares foi o produto que melhor teve resultados para a área de estudo. Entrementes, apesar do pré-processamento na origem, é recomendável a utilização de filtros para reduzir a interferência de ruídos advindos da presença de nuvens, sombras e variações atmosféricas. Em imagens multitemporais, o ruído dificulta a identificação e quantificação dos dados. Todavia, a eliminação do ruído é necessária para adquirir um espectro de qualidade (CARVALHO JÚNIOR *et al.*, 2008; SILVA, 2018).

Nessa direção, o presente trabalho aplicará a combinação das duas técnicas: *Median Filter* (MF) e o *Savitzky-Golay*. Em testes preliminares, os dois filtros alcançaram bons resultados.

O filtro mediana (TUKEY, 1977) elimina os picos isolados em uma série temporal. É um método não linear muito eficaz na redução do ruído, pois o filtro atua ao longo do espectro, minimizando as variações mais bruscas (CARVALHO JÚNIOR *et al.*, 2008, 2012; RAYEGANI *et al.*, 2019; SILVA, 2018).

Nesta pesquisa, usou-se o filtro convolucional de mediana desenvolvido por Carvalho Júnior *et al.* (2008), disponível no *software Abilius*, projetado em linguagem C++, em que o filtro atua ao longo do espectro, cujo tamanho da janela é definido pelo usuário.

O filtro *Savitzky-Golay* (SAVITZKY; GOLAY, 1964), também disponível no *Abilius*, elimina o ruído restante, e seguindo essa lógica, esse filtro suavizará os dados. Esse método é baseado no cálculo de uma regressão polinomial local (de grau x), com pelo menos $x + 1$ pontos, igualmente espaçados para determinar o novo valor de cada ponto. Trata-se de um algoritmo de filtragem e suavização de dados, podendo ser representado pela equação

$$x_i = \frac{1}{2m + 1} \cdot \sum_{j=-m}^m w_j \cdot x_{i+j} \quad (6)$$

Dentro de uma janela de $2m + 1$ amostras do sinal de entrada indexadas em $-m \leq i \leq m$, onde w_i é o conjunto de $x + 1$ coeficientes polinomiais obtidos ao resolver as equações demonstradas (SAVITZKY; GOLAY, 1964). Com o resultado da filtragem, é possível a obtenção de um sinal mais claro e preciso. Assim, são coletadas as amostras de cada unidade delimitada para a obtenção das assinaturas espectrais e posterior classificação.

3.1.3 Classificação

RF

O RF (BREIMAN, 2001), incluso no *Abilius*, refere-se a um meta-estimador que usa

modelos base para combiná-los ou selecioná-los. Encaixa-se, pois, como um classificador por árvore de decisão, a partir de várias subamostras de um conjunto de dados, e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo. Cada árvore é construída independentemente, com base em uma amostra aleatória, sendo o voto da maioria de cada árvore uma previsão. Na árvore, cada nó representa um conjunto de dados do qual saem duas decisões, formando subconjuntos preditores, escolhidos aleatoriamente em cada nó (BAUDRON *et al.*, 2013; BREIMAN, 2001; FERNÁNDEZ-BLANCO *et al.*, 2013; VAN BEIJMA; COMBER; LAMB, 2014).

Embora existam vários outros métodos de classificação supervisionada, o RF já obteve sucesso em estudos sobre a cobertura da terra, por ser um modelo de aprendizagem de máquinas de análise preditiva mais eficaz (CORCORAN; KNIGHT; GALLANT, 2013; CUTLER *et al.*, 2007).

Tendo em vista a aleatoriedade e a capacidade de aprendizagem por conjunto (BREIMAN, 2001, 2012; LIAW; WIENER, 2003), em termos gerais, RF é um método de classificação que pode ser definido como um conjunto do tipo árvore $\{h(x, \theta_k), k = 1 \dots, \}$ em que os $\{\theta_k\}$ são vetores aleatórios independentes, e x é um padrão de entrada.

KNN

A principal funcionalidade do KNN, disponível no *Abilius*, é a seleção de classe a partir da frequência dos itens mais próximos. É um método eficaz na classificação supervisionada a partir do reconhecimento de padrões, ou seja, designa uma abordagem não paramétrica para a classificação e regressão. Na diferenciação de classes, o KNN associa determinado objeto a uma classe, pelo voto de pluralidade de seus vizinhos, sendo atribuído à classe mais comum entre os k vizinhos mais próximos (DENG *et al.*, 2016; MAILLO *et al.*, 2019; NIGSCH *et al.*, 2006; XIA *et al.*, 2015; ZAHED; NAJIB; TAJUDDIN, 2018).

O KNN funciona de forma simples, e existem várias formas para obter seu valor: a mais usada e adotada neste trabalho é a distância euclidiana:

$$d = \sqrt{\sum_{k=1}^n (P_{ik} - P_{jk})^2} \quad (7)$$

onde a distância p_i e p_j são definidas, e P_{ik} e P_{jk} para $k = 1, \dots, h$ são os n atributos que

prescrevem os objetos p_i e p_j , respectivamente (AWAD; KHANNA, 2015; HU *et al.*, 2016; MANNING; RAGHAVAN; SCHÜTZE, 2009).

SVM

Introduzido nos anos 1990 e aplicado à engenharia, o SVM constitui um método de aprendizagem supervisionado que analisa os dados e reconhece padrões (AWAD; KHANNA, 2015). É usado principalmente para classificação, análise de regressão e detecção de fatos não atribuídos ao padrão. Trata-se de uma ferramenta que minimiza os erros estruturais do processo de classificação. É um algoritmo de aprendizagem de máquinas supervisionadas e não lineares que produz bons resultados de classificação (HEUMANN, 2011b; LORENA; CARVALHO, 2007; MOUNTRAKIS; IM; OGOLE, 2011).

De forma simples, o SVM é um classificador binário linear que atribui a determinada amostra pertencer a uma ou outra classe. Por essa razão, uma amostra de dados a ser classificada é um *pixel* unitário de um conjunto maior do cubo de imagens espectrais. Essa amostra, *pixel*, torna-se um padrão para todas as bandas da imagem, constituindo um conjunto de medidas no processo de classificação. O SVM gera um hiperplano n -dimensional a partir dos dados espectrais, em que as classes são separadas com base em uma função *kernel* definida pelo usuário (HEENKENDA *et al.*, 2014; WANG *et al.*, 2014).

4.5.2.4 Análise de acurácia

A acurácia serve para garantir a exatidão dos resultados dos algoritmos de classificação após o processamento dos dados. Nesta pesquisa, para determinar a exatidão da classificação, utiliza-se a matriz de confusão, e os seguintes parâmetros: erro de comissão e omissão; acurácia geral; e por fim, o coeficiente kappa. A análise de Kappa é uma técnica multivariada, discreta, usada na avaliação da precisão para determinar estatisticamente se uma matriz de erro é significativamente diferente da outra (AL-NAJJAR *et al.*, 2019; BEN-DAVID, 2008; BISHOP; HOLLAND; FIENBERG, 1975; FIGUEIREDO; VIEIRA, 2007; FOODY, 2008; IKIEL *et al.*, 2013; SALK *et al.*, 2018; XIA; CHENG; LI, 2019).

A validação dos resultados dos processamentos dos dados pelo coeficiente Kappa é de suma importância, tanto para estabelecer uma precisão como para determinar a possibilidade de os dados e modelos utilizados serem melhorados, se necessário. Nessa perspectiva, a precisão global é a razão entre o número de *pixels* corretamente classificados pelo número total de *pixels*. O coeficiente Kappa é descrito pela seguinte equação:

$$K = \frac{n \sum_{i=1}^c \sum_{j=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (8)$$

onde K é uma estimativa do coeficiente Kappa; x_{ii} é o valor na linha i e coluna i ; x_{i+} é a soma da linha; x_{+i} é a soma da coluna i da matriz de confusão; n é o número total de amostras e c o número total de classes (AL-NAJJAR *et al.*, 2019; ELSAID; ABDELKAREEM, 2018; FIGUEIREDO; VIEIRA, 2007; SALK *et al.*, 2018).

Os resultados da precisão dos classificadores foram comparados de maneira estatística, expressando seus limites de confiança. Outrossim, para comparar os resultados da acurácia, empregou-se o teste McNemar (MCNEMAR, 1947), que é um teste estatístico baseado na Tabela χ^2 (qui-quadrado), sendo usada a seguinte equação:

$$\chi^2 = \frac{(|f_{12} - f_{21}| - 1)^2}{f_{12} + f_{21}} \quad (9)$$

onde f_{12} é o número de *pixels* classificados corretamente com o primeiro classificador, mais *pixels* classificados incorretamente com o segundo classificador; e f_{21} é o número de *pixels* classificados incorretamente com o segundo classificador, mais *pixels* classificados corretamente com o primeiro classificador (FOODY, 2013; MOMENI; APLIN; BOYD, 2016).

À vista disso, o resultado de comparação estatística entre as diferentes classificações é considerado conforme os elementos da Tabela 4. Na avaliação de significância, o valor χ^2 obtido indica a valoração de similaridade ou não entre as classificações; χ^2 inferior a 3.84 (tabela qui-quadrado) indica o grau de similaridade; superior a esse valor reflete o grau de divergência.

Tabela 4 – Teste McNemar entre duas classificações

	Classificação 2		
	Correta	Incorreta	Total
Classificação 1			
Correta	f_{11}	f_{12}	$f_{11} + f_{12}$
Incorreta	f_{21}	f_{22}	$f_{21} + f_{22}$
Total	$f_{11} + f_{21}$	$f_{12} + f_{22}$	$f_{11} + f_{12} + f_{21} + f_{22}$

Fonte: MCNEMAR, 1947

A acurácia e a validação dos resultados por meio do coeficiente Kappa são fundamentais para garantir a precisão dos algoritmos de classificação após o processamento dos dados. Logo, a utilização de parâmetros como erro de comissão e omissão, acurácia geral e o coeficiente Kappa são meritórios para avaliar a exatidão da classificação.

Ademais, o teste McNemar é uma técnica útil para comparar os resultados da acurácia e expressar seus limites de confiança. A partir dessas ferramentas estatísticas, é possível avaliar a similaridade ou divergência entre as diferentes classificações, permitindo a identificação de possíveis melhorias nos modelos e dados utilizados.

5 RESULTADOS

5.1 Sentinel-1

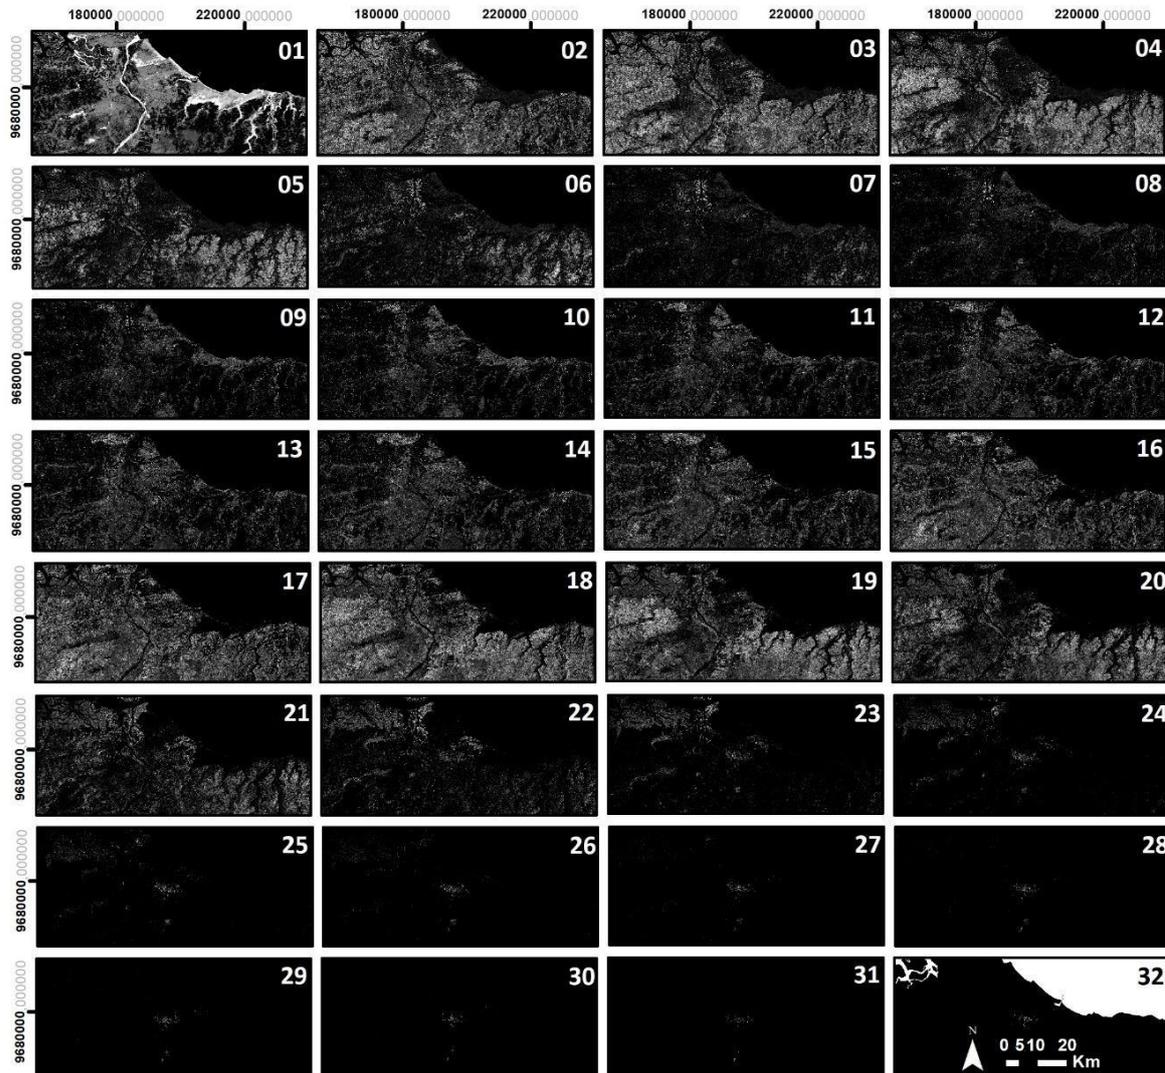
5.1.1 PDCA e MNF

Como resultado da transformação PDCA do cubo de imagens Sentinel-1, polarização VV e VH intercalados, compreendendo um conjunto temporal de 08/04/ 2017 a 21/05/2018, totalizando 66 imagens, obtiveram-se 32 bandas multicomponentes, cada um representando uma frequência do histograma resultante do processamento.

Dessa forma, cada imagem resultante ou conjunto de imagens produto permite identificar uma feição da superfície terrestre. No exemplo da Figura 9, a imagem 1 revela os corpos hídricos e campos de areias quartzosas; de 2 a 4, a vegetação rasteira e psamófila; 22 e 24 evidenciam a vegetação de mangue; 26 a 31; pontos de urbanização. Essas três classes estão dispostas em gradação, mostrando a distribuição do retroespalhamento.

Tendo isso em vista, a relação sinal-ruído, em valores de frequência, dispõe as classes como águas continentais e sedimentos quartzosos de baixa intensidade na primeira banda. Com o aumento da frequência das classes, vão-se dispondo nas bandas de maior valor (Figura 10). Assim sendo, os multicomponentes gerados são passíveis de classificação.

Figura 9 – Imagens resultantes do processo PDCA a partir das imagens Sentinel-1 polarização VV e VH (08/04/2017 a 21/05/2018)

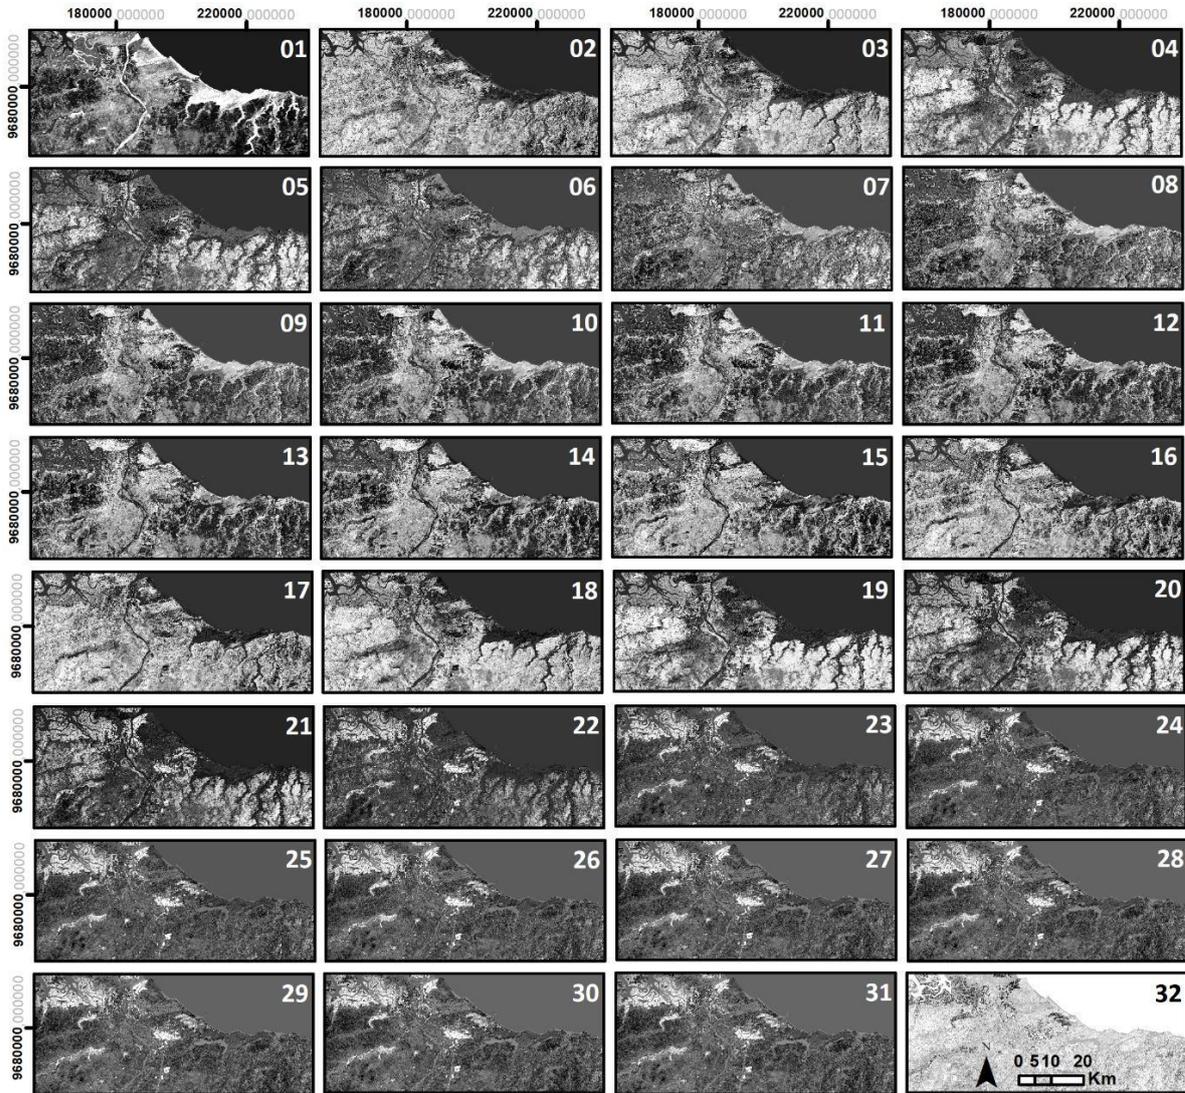


Fonte: Elaboração Própria (2022).

Nesse conjunto de imagens, resultante do processamento PDCA, em que foi gerado um cubo de 32 imagens, aplicou-se a transformação MNF (Figura 10) para reduzir a dimensionalidade dos dados multicomponentes, segregando o ruído nos dados.

Assim, o produto resultou em dados com variação de unidade sem correlação de banda com banda. Trata-se de um reordenamento dos dados de frequência do PDCA. Após o MNF, aplicou-se a transformação MNF inversa, de modo que as bandas são realocadas em seu espaço original. Contudo, as imagens dominadas por ruídos são suavizadas, e nesse processo, as imagens com concentração de ruídos são eliminadas. As imagens geradas apresentam nitidez sem o ruído.

Figura 10 – Imagens componentes MNF resultantes do processamento das componentes PDCA

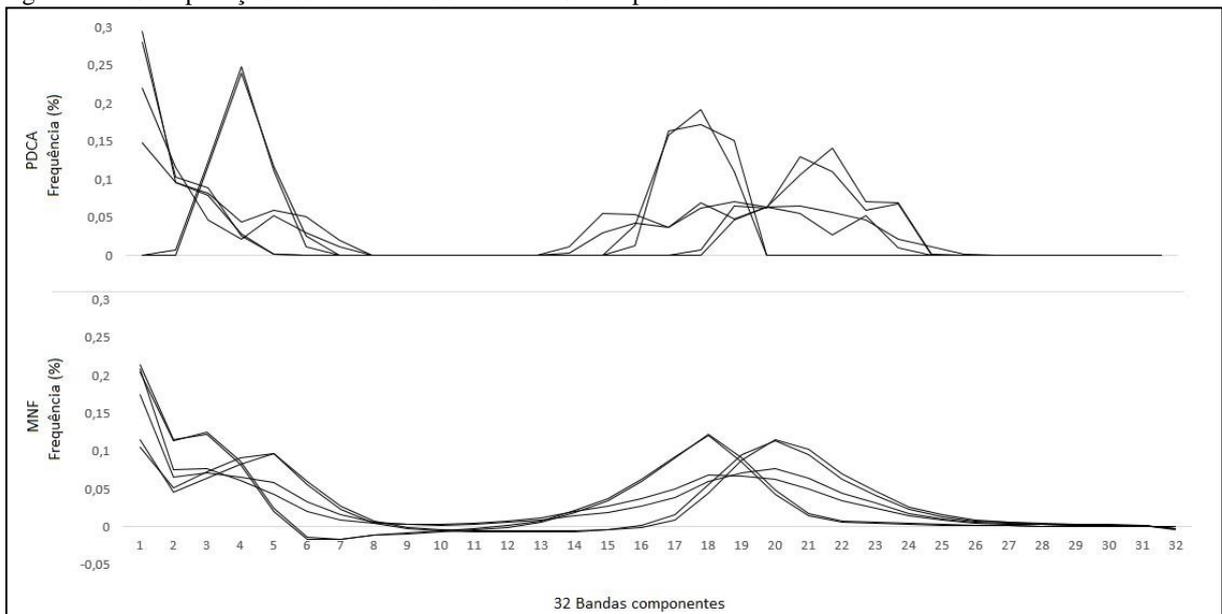


Fonte: Elaboração Própria (2022).

A aplicação da MNF inversa considera apenas os conjuntos iniciais de imagens, pois as imagens ruidosas se concentram nos conjuntos finais (Figura 9). Desse modo, a MNF é um processo de filtragem que proporciona a suavização dos dados, ordenando os ruídos que se encontram nas últimas bandas.

Com efeito, para esses dados, a MNF inversa considerou as cinco primeiras bandas, o que proporcionou melhor suavização (Figura 10). Por certo, a normalização dos dados dos *pixels* facilita o uso dos algoritmos classificadores.

Figura 11 – Comparação dos valores das bandas PDCA e após a inversa MNF



Conjunto de valores de *pixels* para a classe analisada (manguezal) representando três conjuntos de dados com curvas distintas. Para o uso de dados de radar, é importante a inserção de dados desse tipo para melhor classificação. A presença de valores altos, distorcendo a curva, é resultado da limitação do método, pois a classe caracterizada como “mar” apresentou valor zero após a filtragem mediana.

Fonte: Elaboração Própria (2022).

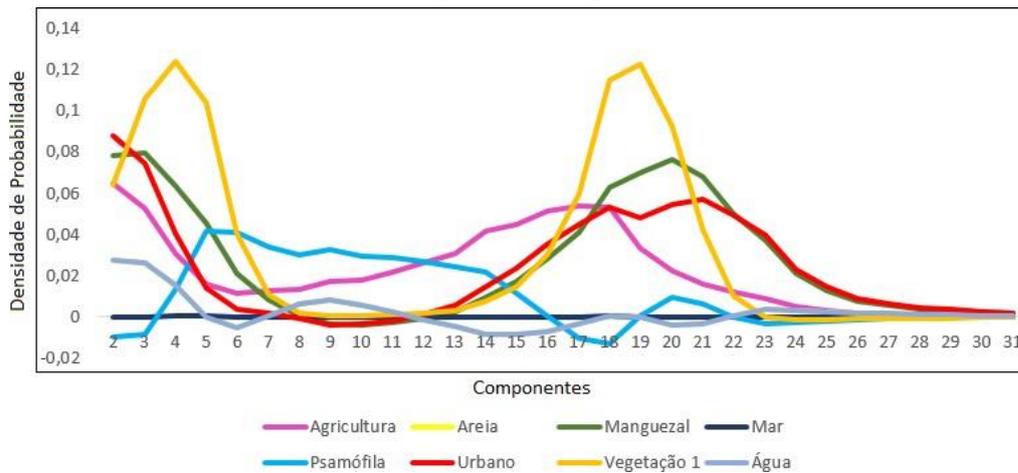
5.1.2 Classificação

A partir da extração da média dos valores dos *pixels*, é possível verificar a curvatura dos valores, a frequência nas componentes de probabilidade (Figura 11). A curva água e areias quartzosas (dunas, lenções de areia e praia) tem a mesma resposta de curvatura, e a maior parte é registrada na primeira banda: são duas classes cujo sinal é praticamente refletido em ângulo reto, e pouco sinal é recebido pelo sensor.

Com a variação do sinal na banda VV e VH, o gráfico (Figura 11) mostra dois picos de sinal que se conjunta nas bandas 3 a 6, e 17 a 22. Essa resposta na frequência é considerável para a delimitação do manguezal, que tem uma resposta mais alta entre as bandas 18 e 21, resultado dos três conjuntos de valores mostrados na Figura 10.

Por conseguinte, o gráfico (Figura 12) é uma visualização da resposta da frequência do sinal de radar combinando as distintas respostas de sinal das bandas VV e VH, e as duas curvas de uma mesma classe se complementam para posterior classificação. Logo, o gráfico é uma resposta do pulso de radar combinando as duas polaridades.

Figura 12 – Assinaturas de densidade de probabilidade para a área de estudo



Assinatura do PDCA para as diferentes classes selecionadas, mostrando em dados de frequência a curvatura de resposta do sinal de radar para cada uma delas, a categoria “mar” foi inserida apenas para fim de classificação, pois logo após a filtragem por mediana assumiu valor zero e concentrando na última banda.

Fonte: Elaboração Própria (2022).

No conjunto de dados, os experimentos foram aplicados em dois cubos de imagens SAR Sentinel-1: um com polarização VV; e outro; VH. Assim: (1) realizou-se a filtragem por mediana em cada cubo, com 33 imagens, cada; (2) os cubos foram fundidos em um único cubo, intercalando bandas VV e VH; (3) realizou-se o PDCA, resultando em um cubo com 32 bandas de frequência; (4) posteriormente, realizou-se a MNF e MNF inversa, utilizando dados de estatística até a quinta banda; (5) classificação.

Para fins de verificação do melhoramento pelo método proposto, executou-se o procedimento do cubo de imagens sem qualquer processamento, somente o empilhamento das bandas VV e VH intercaladas, em um total de 66 imagens para classificação.

As imagens foram classificadas por meio das medidas espectrais, que aqui dizem respeito às respostas em curvatura da densidade de probabilidade, distintas para cada classe selecionada. As amostras foram coletadas em dois conjuntos: manguezal e não manguezal. O não manguezal compreende um conjunto de classes utilizadas para potencializar o resultado do conjunto de *pixels* manguezal, diminuindo o erro da resposta do classificador. As amostras foram coletadas aleatoriamente em cada classe – 300 *pixels* cada para compor o conjunto de dados de treinamento.

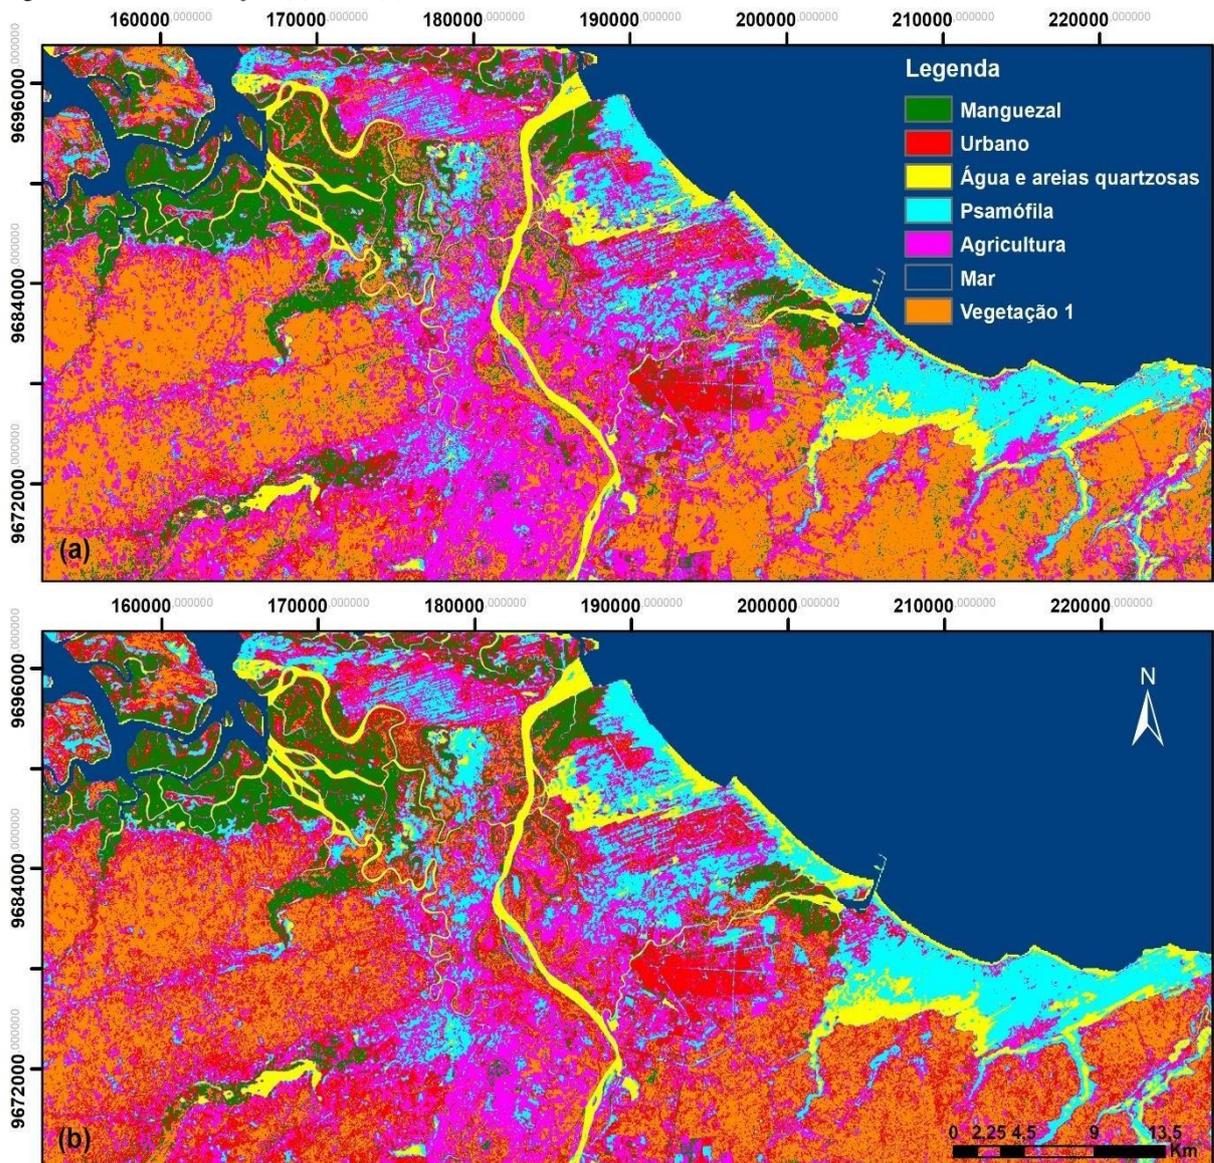
5.1.2.1 RF e KNN

Como resultado do processamento PDCA-MNF, obteve-se um produto ideal para a classificação. Porém, os ambientes costeiros impõem limitações para o uso de dados SAR em virtude de a resposta do sinal de radar ser muito idêntica em algumas classes selecionadas,

impossibilitando sua diferenciação, como no caso de vegetação psamófila; áreas de campos e campo cerrado; áreas agrícolas e periferia urbana; águas continentais e areias quartzosas (dunas, lençóis de areia e praias).

No entanto, para a distinção de vegetação arbórea, são válidos, nesta pesquisa, os dois métodos de classificação (RF e KNN) que discriminam o manguezal de outras classes, como também a vegetação secundária, aqui nomeada de vegetação 1 (Figura 13-a e 13-b).

Figura 13 – Classificação (a) RF e (b) KNN



Fonte: Elaboração Própria (2022).

5.1.3 Análise de acurácia

Os resultados indicam que os classificadores RF e KNN são capazes de lidar com conjuntos de dados propostos gerando boa precisão de classificação, delimitando as florestas de mangue. A Tabela 5 lista os índices de acurácia para as classificações de mangue por RF e KNN, com os dados originais (dados brutos) e o processamento PDCA-MNF. Os modelos baseados nos dados originais obtiveram um coeficiente Kappa (80% KNN e 81% RF) inferior aos dados processados pelo PDCA-MNF (88% KNN e 89% RF).

Tabela 5 – Avaliação de precisão dos modelos RF e KNN do mapeamento das extensões de manguezal. Melhor resultado indicado em negrito

	Dados originais				PDCA-MNF			
	Erros de comissão (%)	Erros de omissão (%)	Precisão Geral (%)	Índice Kappa	Erros de comissão (%)	Erros de omissão (%)	Precisão Geral (%)	Índice Kappa
RF	12,80	50,75	81,99	0,59	7,90	27,86	89,43	0,74
KNN	27,27	40,09	80,57	0,52	4,36	34,75	88,29	0,70

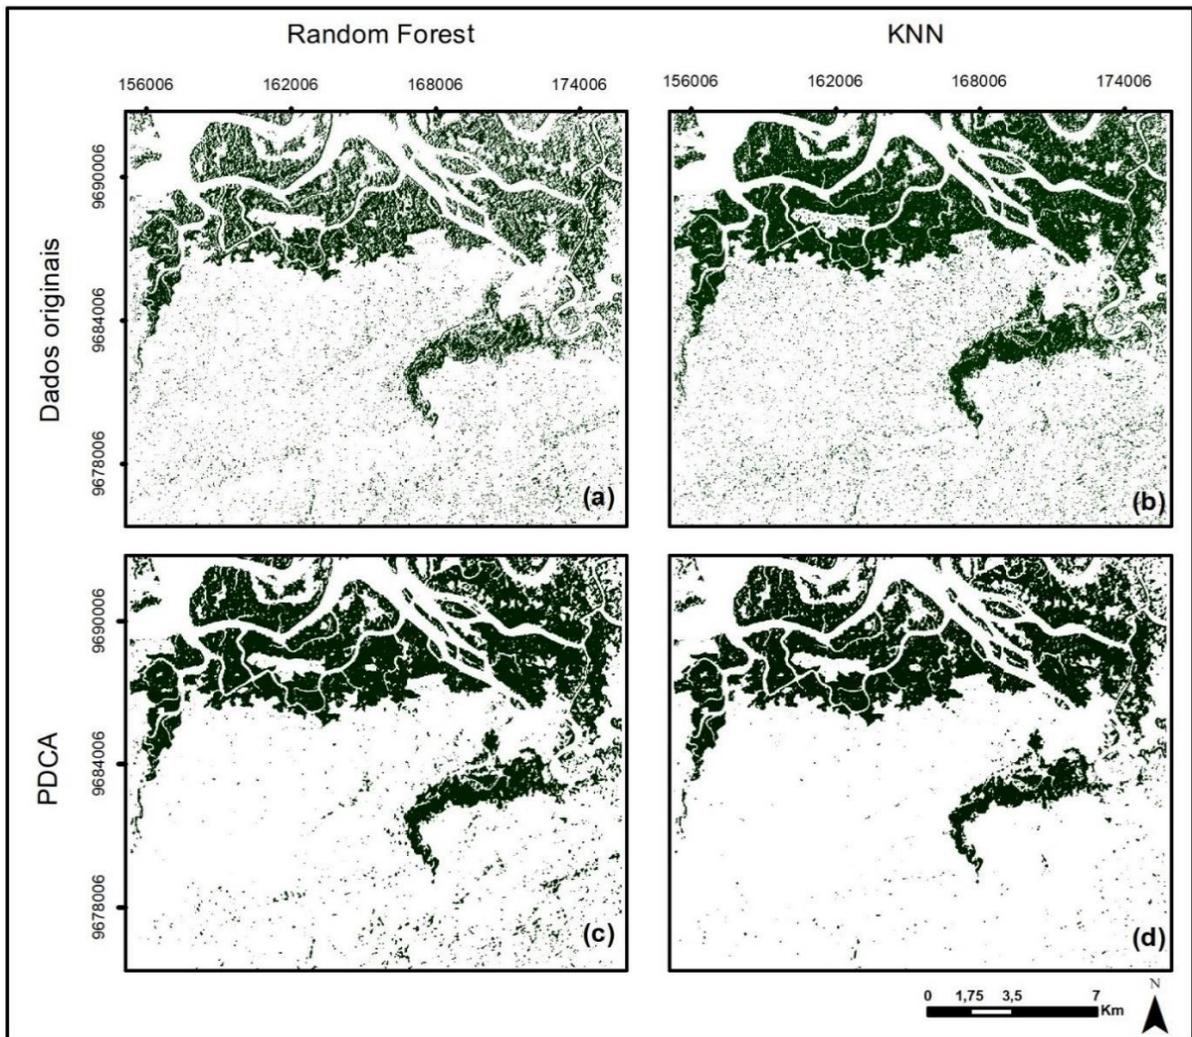
Fonte: Elaboração Própria (2022).

Com base na interpretação visual dos mapas de extensão da vegetação do manguezal (Figura 14), as Figuras 14-c e 14-d apresentam resultado mais suave e consistente, enquanto os resultados 12-a e 12-b exibem resquícios granulares. Apesar de um resultado Kappa melhor dos experimentos (RF no processamento PDCA) mostrar uma porcentagem maior de erros de comissão (7,90%), isso dá-se em razão de o produto PDCA-MNF conservar resquícios do sinal próprios das imagens SAR, a relação sinal/ruído.

No entanto, apesar do resultado de erro de comissão, a utilização as polarizações VV e VH amplifica o poder de intensificação das extensões de manguezal, o que é melhor observado na Figura 14-c RF, 14-d KNN.

Os dados originais classificados apresentaram um resultado peculiar na classificação, apesar da alta precisão geral (81,99%). O RF resultou em elevados erros de omissão (50,75%), impactando no Índice Kappa de modo não expressivo (0,59). O KNN acompanha também os erros de comissão de 40,09, mas é visivelmente mais consistente (Figura 14-b). Não obstante, nos experimentos RF do processamento PDCA, houve uma melhora expressiva nos erros de comissão (27,86%) e erros de omissão baixo (7,90%).

Figura 14 – Resultado do Índice Kappa para delimitação do manguezal



Fonte: Elaboração Própria (2022).

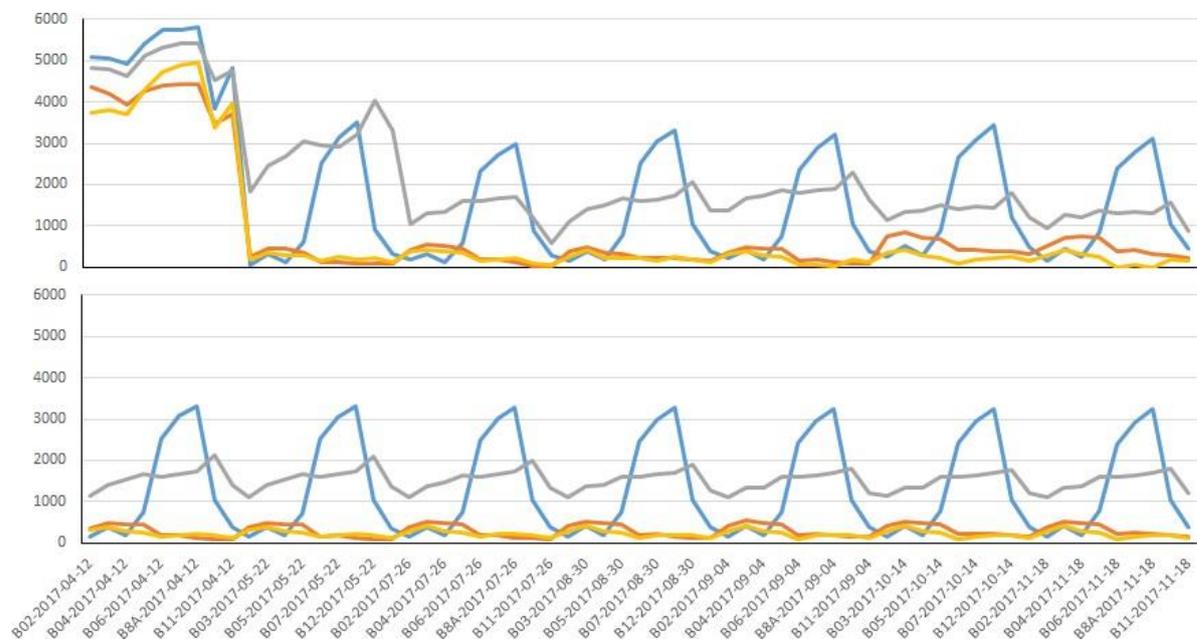
A Figura 14 mostra que o manguezal é classificado com sucesso maior, apesar do melhor resultado visual no KNN, originário do processamento PDCA-MNF (Figura 14-d). Nãoobstante, o melhor Índice Kappa é do *Random Forest* (Figura 14-c). A fusão intercalada das polaridades VV e VH melhora a identificação das extensões das florestas de mangue – esse resultado confirma a capacidade do método na identificação e é útil para a classificação de vegetação, como demonstrado anteriormente por outros pesquisadores (CARVALHO JUNIOR *et al.*, 2014; MARQUES *et al.*, 2019).

5.2 Sentinel-2

5.2.1 Filtragem do ruído

O cubo multiespectral nas dimensões x, y e z apresenta em sua primeira imagem (Figura 15-a) bandas com valores altos, em decorrência da presença de nuvens. Na Figura 15-b, o espectro foi suavizado pela filtragem por mediana, mas o sinal mantém um padrão mais constante em todas as imagens e respectivas bandas. A filtragem por *Savitzky-Golay*, proporcionou uma suavização dos dados para ampliar sua precisão, sem distorcer a tendência do sinal. Na Figura 15-c, o sinal apresenta uma tênue suavização, alinhando os picos de maior intercidade.

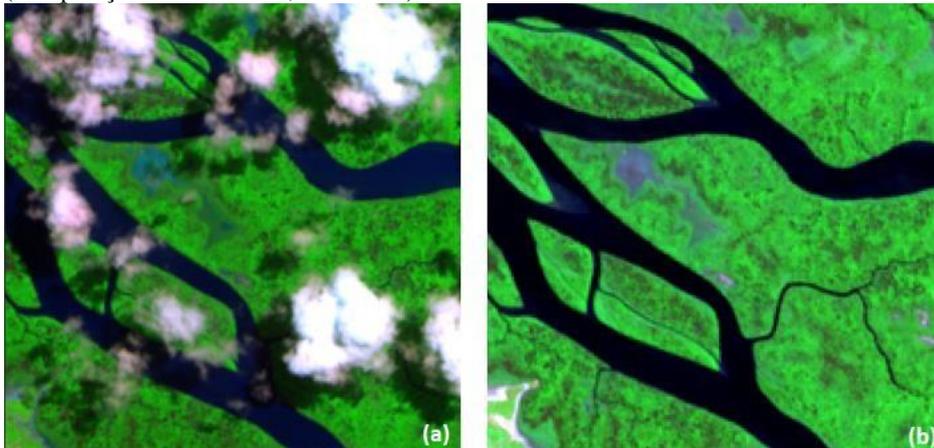
Figura 15 – Resultado dos diferentes estágios do espectro de pixels aleatórios: (a) dados primários; (b) filtro mediana e Savitzky-Golay



Fonte: Elaboração Própria (2022).

O procedimento utilizado permitiu a correção de imagens multiespectrais, gerando um dado de cada *pixel* a um padrão passível de classificação. A correção espectral também é visível na qualidade na imagem resultante (Figura 16).

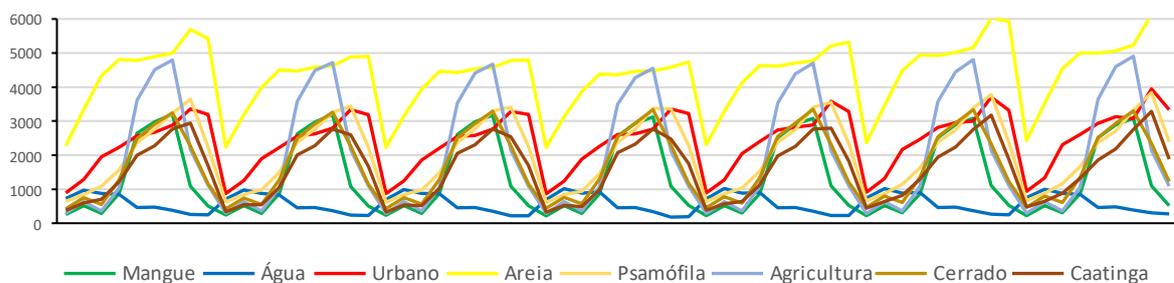
Figura 16 – Resultado dos diferentes estágios: (a) dados primários; (b) filtro mediana e Savitzky-Golay (composição SWIR – B12, B8A e B4)



Fonte: Elaboração Própria (2022).

Os resultados experimentais das imagens classificadas, mostram que ao fazer uso dos valores das bandas de cada imagem em serie temporal é possível seccionar cada unidade classificada (Figura 17). Como esperado os picos de reflectância de vegetação foram maiores na banda B08A, a banda B08 (NIR, infravermelho próximo) não foi utilizada em razão da intercidade do sinal. A curva de areia quartzosas, que representa os depósitos sedimentares (dunas, lenções de areia e praia, e outros ambientes deposicionais), apresenta alta intercidade de sinal.

Figura 17 – Assinaturas espectrais usadas na classificação



Fonte: Elaboração Própria (2022).

Ao analisar a curvatura de sinal dos dados S-2 (Figura 17), nota-se que a diferença dos dados é mais acentuada nas bandas Red Edge (B05, B06, B07 e B8A), sendo mais representativos nos dados de vegetação. Ademais, é nas B06 e B07 onde se pode destacar os valores de agricultura, com maior intercidade de sinal. As bandas *blue*, *green* e *red*, por sua vez, contam com menor intercidade de sinal.

Nesse conjunto, os maiores valores são áreas urbanas e áreas quartzosas – são essas bandas que acentuam a curvatura de corpos hídricos que apresentam baixa reflectância nas outras bandas. As bandas *SWIR* 1 e 2 apresentam valores divergentes quanto à intercidade, para

1 é maior que 2, e releva a curva de áreas quartzosas e urbano. Ficam evidentes, pois, as diferenças entre cada classe analisada.

A vegetação de mangue não apresenta linha fenológica aparente em análise temporal, capaz de diferenciar o espectro com os outros tipos de vegetação, principalmente de mata ciliar, apicuns, vegetação de borda de mangue e entre os diferentes tipos de mangue, por constituir um vegetação cuja presença de água no substrato não depende das variações climáticas, mas da dinâmica das marés.

Com efeito, há pouca mudança na reflectância da vegetação de mangue em um ciclo climático. Os diferentes tipos de abordagem para classificação de imagens para zonas costeiras superestimam ou reduzem as dimensões das áreas de manguezal, ou classificam-nas erroneamente. Por essa razão, o conjunto de dados utilizados na classificação foi empregado para definir a presença ou ausência de vegetação de mangue.

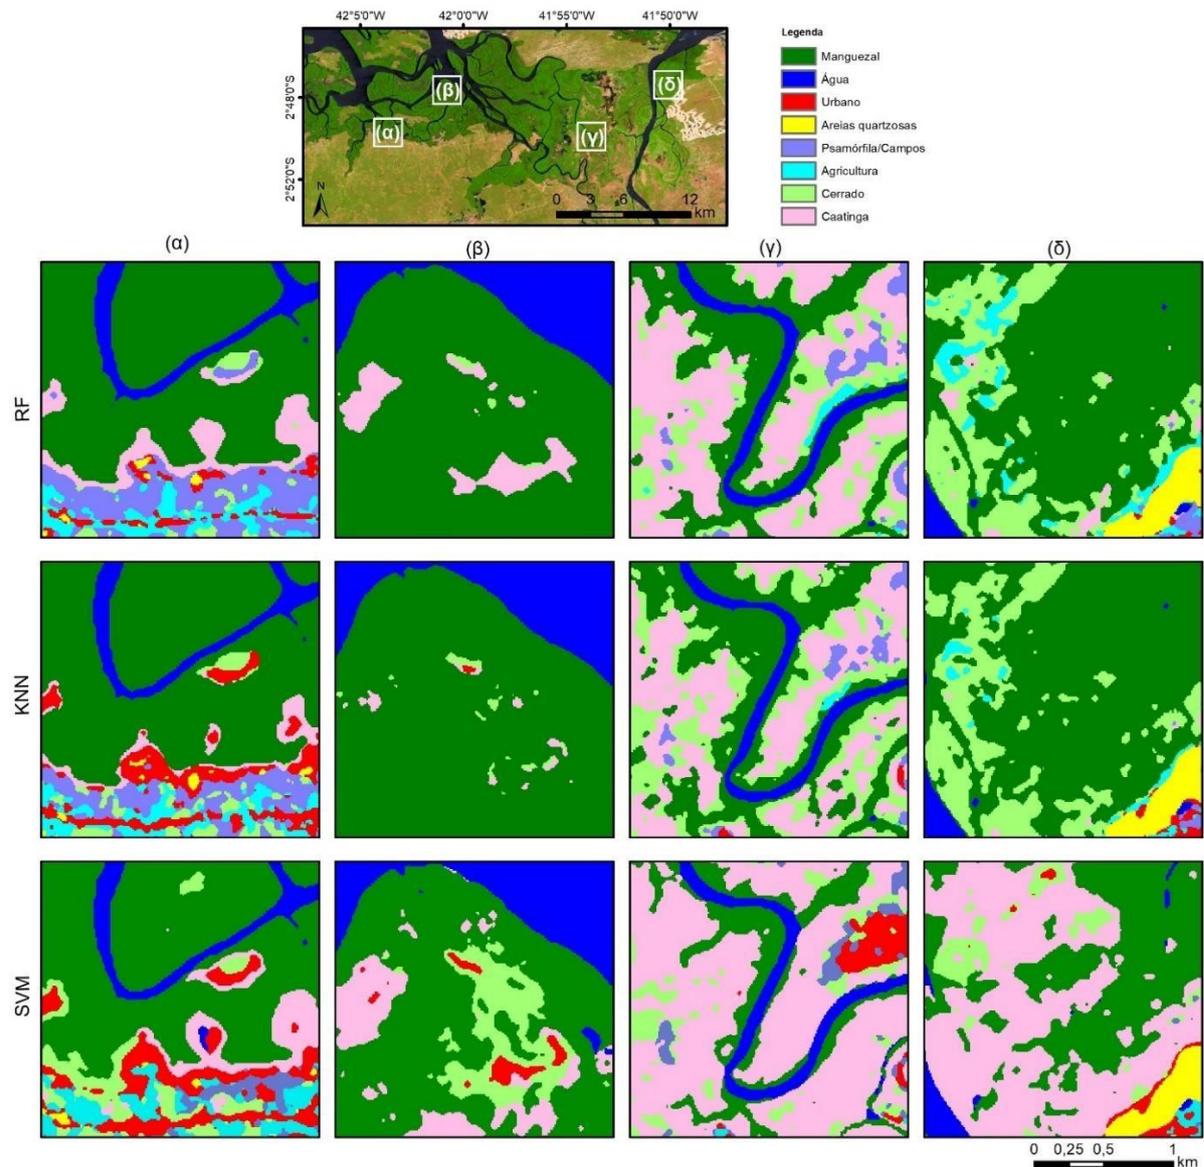
Os experimentos posteriores foram aplicados nesse cubo. Para a classificação RF e KNN, as medidas espectrais foram coletadas e verificadas as distinções temporais e espectrais entre manguezal e não manguezal. Aqui, não manguezal compreende o conjunto de classes que foram utilizadas para potencializar os resultados da classificação, minimizando o erro do algoritmo classificador. As amostras foram coletadas em cada classe em um total de 300 *pixels* por classe para o treinamento do classificador.

5.2.2 Classificação: RF, KNN e SVM

As imagens óticas dos diferentes sensores encontram limitações de uso para ambientes costeiros, e um dos motivos alude ao fato de os resultados de classificação divergirem da verdade espacial da área de estudo. No entanto, os resultados são mais homogêneos e apresentam uma qualidade superior aos produtos resultantes de dados de radar.

Nas duas classificações (Figura 18), vegetação de mangue, Cerrado, Caatinga, água e areias quartzosas apresentaram resultados coerentes, contudo, a classe vegetação psamófila, que se limita aos ambientes pós-praia, dunas e áreas entre o mangue e mar, ultrapassou esses limites, pois se confundiu com pastagens, áreas desmatadas e áreas agrícolas de entressafra. Áreas urbanas também foram superestimadas nos dois classificadores. O RF (Figura 18-RF) confunde o rastro de dunas fixas vegetadas com o arruamento urbano, e o mesmo foi observado no KNN (Figura 18-KNN). No SVM, o urbano diverge, com áreas de vegetação e a borda de dunas.

Figura 18 – Assinaturas espectrais usadas na classificação



Fonte: Elaboração Própria (2022).

5.2.3 Análise de acurácia

Os resultados finais desvelaram que os dados S-2 mostram que a classificação por RF tem melhoria na precisão geral de 96,78% (Tabela 6), com Kappa de 0,9261. O KNN teve resultado significativo, denotando evolução de precisão geral de 97,77, e Kappa final de 0,9264 (Tabela 6). Nos dois casos, os resultados são excelentes.

Tabela 6 – Avaliação de precisão da classificação de RF, KNN e SVM, no mapeamento das extensões de manguezal. Melhor resultado em negrito

Classificação	Erros de comissão (%)	Erros de omissão (%)	Precisão Geral	Índice kappa
---------------	-----------------------	----------------------	----------------	--------------

	Mangue	Não Mangue	Mangue	Não Mangue	(%)	
RF	5,21	2,28	4,82	2,47	96,78	0,9261
KNN	6,50	1,61	3,36	3,17	96,77	0,9264
SVM	4,16	6,88	16,17	1,64	93,86	0,8513

Fonte: Elaboração Própria (2022).

No tocante à delimitação do mangue, as classificações resultantes da aplicação do SVM, RF e KNN podem ser observados na Tabela 6. O SVM apresentou a maior omissão de dados floresta de mangue, apesar de ser uma das classes mais homogêneas (Tabela 7).

Tabela 7– Avaliação da precisão a partir da verdade do solo

	Ground truth class					
	Mangrove			Non-mangrove		
	KNN	RF	SVM	KNN	RF	SVM
Mangrove	96,64	95,18	83,83	3,17	2,47	98,36
Non-mangrove	3,36	4,82	16,17	96,83	97,53	1,64

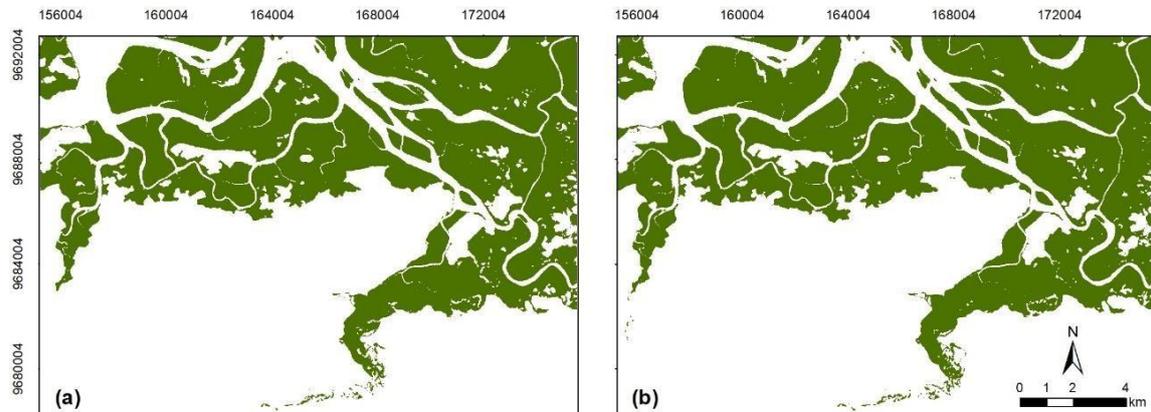
Fonte: Elaboração Própria (2022).

Na linha de qualidade do mapeamento temático, o confidante Kappa apresentou resultado excelente, e imagens homogêneas a sem resquícios granulométricos característicos de dados de radar (Figura 19). Nas duas classificações, os erros de comissão RF e KNN chegaram a 4,82% (Figura 19-a) e 3,36% (Figura 19-b), respectivamente.

Em razão da homogeneidade da classificação, é quase imperceptível a visualização das melhorias em um classificador e outro. O KNN apresenta melhor resultado final, com menor erros de comissão de 3,36%, ou seja, é o melhor resultado geral de todas das classificações realizadas.

Deveras, a utilização de dados espectrais de distintas bandas do S-2 melhora a identificação e separabilidade de classes para a zona costeira, e potencializa a identificação das extensões de manguezal, com melhorias significativas. Ratifica-se, pois a capacidade do método na identificação desses ecossistemas.

Figura 19 – Resultado do Coeficiente Kappa para delimitação do manguezal (SVM)



Fonte: Elaboração Própria (2022).

McNemar

Como visto na Tabela 8, no teste McNemar, χ^2 os valores para KNN x RF foram 1,29, e para KNN x SVM e RF x SVM para as áreas de mangue, constituíram 46,59 e 54,40 respectivamente, com intervalo de 95% de confiança dos valores calculados por χ^2 , onde $\chi^2 > 3.84$ mostra diferença significativa. Portanto, os resultados χ^2 para KNN x RF são classificações equivalentes.

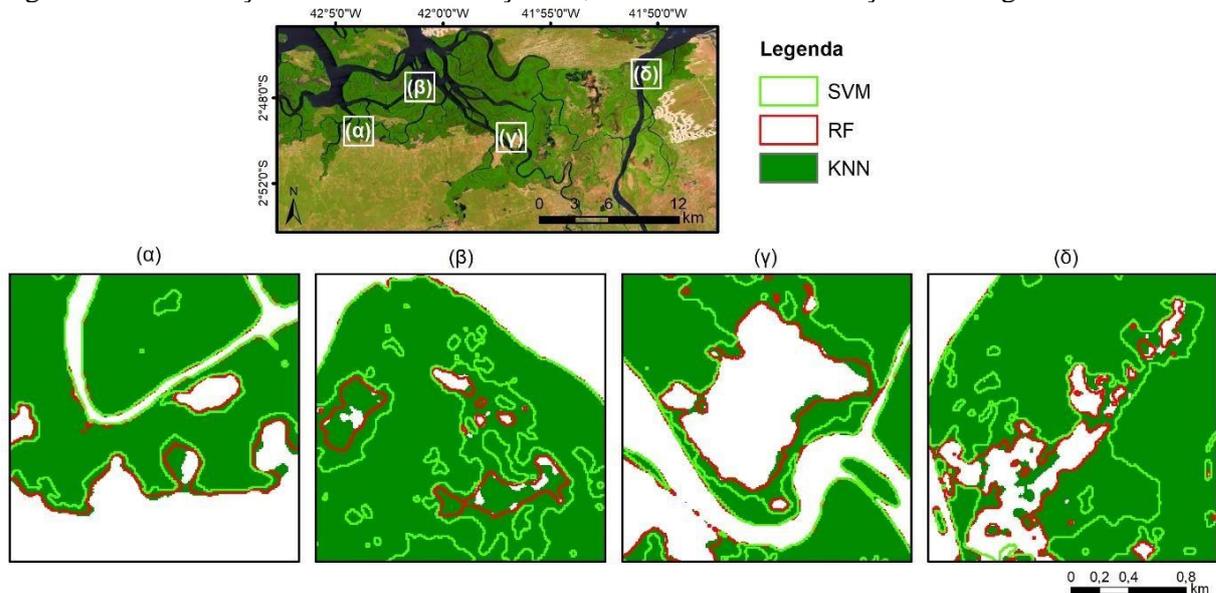
Tabela 8 – Avaliação da diferença entre os resultados da classificação com o teste McNemar realizado com 5.000 pontos da amostra

Classificação x Classificação	<i>F11</i>	<i>F12</i>	<i>F21</i>	<i>F22</i>	Total	χ^2 resultado
KNN x RF	4.793	27	36	144	5.000	1,29
KNN x SVM	4.577	227	103	93	5.000	46,59
RF x SVM	4.552	241	104	103	5.000	54,40

Fonte: Elaboração Própria (2022).

Na Figura 20, demonstra-se, conforme o teste McNemar, a comparação entre os três classificadores utilizados. O KNN e RF, quando confrontados, tiveram χ^2 resultado 1,29, possuindo menor índice de diferença. Contudo, o SVM apresentou maior índice de diferença entre os outros classificadores.

Figura 20 – Diferença entre as a classificação RF, KNN e SVM: delimitação do mangue



Fonte: Elaboração Própria (2022).

Três abordagens para a classificação de uso do solo e delimitação das extensões de manguezais foram comparadas a partir das espectrais de diferentes bandas das imagens S-2 em série de datas, as melhores imagens de um ano, sendo selecionadas as imagens com menor cobertura de nuvens.

No tocante à precisão da classificação, apesar de não completar um ano do ciclo climático, em decorrência de quadro meses com cobertura de nuvens e algumas datas do período com alta porcentagem de muitas nuvens, a preocupação maior foi com a qualidade dos dados e coleta de dados de treinamento, o que consumiu maior parte do tempo em relação a todo o experimento.

Nesta pesquisa, 25% da área foi destinada à validação pelo coeficiente Kappa, com base nas matrizes de confusão de dados das três diferentes técnicas de classificação. Para o processamento da acurácia, usaram-se dados reais sobre a delimitação da floresta de mangue do Ministério do Meio Ambiente (2010). Cabe resultar que dados verdade muitas vezes estão defasados e/ou a informação não condiz 100% com a verdade terrestre – geralmente tais dados oficiais são resultados de processamentos automatizados ou por análise visual.

Como elucidado nesta pesquisa, a acurácia final depende de muitos fatores primários e do próprio processamento, assim como dos dados verdade. Assim, foi revelado nas discussões que a diversidade de ambientes interfere na classificação e tem impacto direto na acurácia final.

Para as áreas litorâneas, a mistura de classes de vegetação, como psamófila e pasto, acaba provocando confusão em relação à distinção, porquanto grandes ou menores áreas de mangue e espécies diferentes têm a mesma reflectância.

Em estudos futuros, os dados S-2 em séries mais longas e multiespectrais podem melhorar a delimitação das áreas de mangue, e o mapeamento do uso do solo, com maior precisão e detalhamento. Outro aspecto é a melhoria dos algoritmos de classificação, dando mais precisão e detalhamento.

6 DISCUSSÃO

Para melhor visualização e compreensão dos ecossistemas de mangue, mapear os detalhes dos manguezais é um dos métodos mais eficazes (DHINGRA, KUMAR, 2019).

Como uma abordagem relativamente robusta e diferente, poucos estudos de sensoriamento remoto utilizaram PDCA, e aqui, de forma pioneira, com a utilização de séries temporais para a detecção de manguezais, e mais restrito ainda com a utilização de imagens de radar. É um campo da ciência pouco explorado, e a maioria dos estudos concentra-se em imagens óticas e fora dessa linha metodológica. De acordo com a literatura, apenas dois trabalhos científicos enveredaram o uso de PDCA em imagens de radar para classificação na detecção de florestas de mangue – esta tese é primeira (CARVALHO JUNIOR *et al.*, 2014; MARQUES *et al.*, 2019).

O PDCA em uma série temporal de dados Sentinel-1 segmenta os dados com base em suas características de densidade e probabilidade, envolvendo a criação de uma função de densidade de probabilidade a partir dos dados de entrada, o que representa a distribuição de valores no conjunto de dados. Assim, calcula-se a probabilidade de cada segmentação da imagem pertencer a determinado tipo de classe ou cobertura do solo, com base em sua localização na função de densidade. Essa abordagem é particularmente útil para separar classes que possuem assinaturas espectrais sobrepostas, como diferentes tipos de vegetação, entre elas, as florestas de mangue.

Nessa perspectiva, além da utilização de janelas móveis para a elaboração de curvas de densidade de probabilidade, gerando multicomponentes que minimizam o ruído, proporciona-se a classificação (CARVALHO JUNIOR *et al.*, 2014).

Nesta pesquisa, o fator temporal é atribuído ao cubo na janela móvel, somando-se a dimensão espacial em uma linguagem 3D. Com a utilização da MNF e MNF inversa, tem-se uma suavização do sinal, eliminando por fim as frações ruidosas restantes do cubo PDCA.

Apesar de este trabalho ter usado apenas dois anos de imagens de SAR, os resultados mostram sua aplicabilidade para a classificação e delimitação de florestas de mangue. Pesquisas posteriores podem fornecer mais detalhes sobre esse processo, facultando uma aprendizagem profunda.

Sabe-se que a qualidade dos resultados da classificação depende diretamente das características de entrada (GHORBANIAN; MOHAMMADZADEH, 2018; GHORBANIAN; MAGHSOUDI; MOHAMMADZADEH, 2020). Portanto, a implementação de classificação

para produtos de satélites de múltiplas fontes (ou seja, SAR ou óptica) pode ampliar o poder de análise, interpretação e discriminativo de um classificador (WANG *et al.*, 2019).

Adicionalmente, dados de satélite de séries temporais podem revelar flutuações do nível da água em estuários, como ecossistemas de mangue (WANG *et al.*, 2019). Portanto, conjuntos de dados sazonais podem mitigar os efeitos das marés na área de estudo e permitir a geração de mosaicos livres de nuvens.

Usando imagens de satélite, diferentes algoritmos de classificação foram empregados para mapear as florestas de mangue (MANNA; RAYCHAUDHURI, 2018; QUANG *et al.*, 2020; MONDAL *et al.*, 2019).

Nesse sentido, a escolha do classificador mais adequado não é importante apenas para a escolha de recursos discriminativos, mas afeta diretamente os resultados da classificação. Dentre os classificadores, o RF provou ser um algoritmo eficaz em estudos de mapeamento de florestas de mangue (ZHAO; QIN, 2020; TOOSI *et al.*, 2019; NABABA *et al.*, 2020).

Por exemplo, Toosi *et al.* (2019) compararam quatro classificadores não paramétricos comumente usados (ou seja, RF e SVM, com núcleos de função de base linear e radial, e análise discriminante regularizada) para mapeamento de ecossistema de mangue, e concluiu que o classificador Think RF é melhor, no caso de dados óticos.

Neste estudo, um classificador de RF para os dados provenientes da metodologia empregada para dados SAR (Sentinel-1) provou ligeiramente ter melhor desempenho. Em trabalhos que se alinham com este, tendo como base dados óticos em pixel, também se comprovou o grande potencial para o mapeamento do ecossistema de mangue manguezais (ZHAO; QIN, 2020; TOOSI *et al.*, 2019; NABABA *et al.*, 2020).

Sem embargo, quanto aos dados óticos (Sentinel-2) e ao processamento aqui empregados, na classificação, o KNN obteve coeficiente suavemente melhor que o RF. Portanto, o mosaico de imagem final contendo dados de séries temporais do Sentinel-1 e do Sentinel-2 foi alimentado no classificador de KNN e RF, respectivamente. O classificador de RF possui vários parâmetros de ajuste que afetam a fase de treinamento da etapa de classificação e, portanto, afetam diretamente o resultado da classificação.

7 CONCLUSÃO

Os mapas de identificação de florestas de mangue da presente pesquisa mostram que o método PDCA e MNF utilizando os dados intercalados no cubo temporal nas polarizações VV e VH, revela que os algoritmos para classificação RF e KNN podem ser utilizados com êxito.

Trata-se de uma nova abordagem para o tratamento de dados SAR. A transformação em dados de frequência multicomponentes preserva as vantagens das duas polarizações, maximizando o poder de classificação e, conseqüentemente, a detecção, o mapeamento e o monitoramento temporal das florestas de mangue, objetivo do presente estudo.

Assim, a grande vantagem dos dados SAR pode ser assim descrita: a transparência atmosférica e a independência da luz solar, permitindo uma sequência periódica melhor que os dados óticos, proporcionando um monitoramento contínuo, aproximando-se com maior veracidade da fenologia vegetal.

Aqui cabe ressaltar a utilização da polarização VV e VH, utilizada alternadamente em um cubo, que permitiu uma complementariedade mais acurada dos sinais recebidos pelo sensor, ao mesmo tempo proporcionando uma diminuição dos efeitos da polarização, os quais podem ser exemplificados na interação do sinal do radar com o meio natural que modifica a polarização do sinal – a polarização dupla e cruzada minimiza esse efeito.

Perante os resultados obtidos, pode-se afirmar que a utilização do método PDCA-MNF permite uma boa diferenciação de vegetação e delimitação de florestas de mangue. O trabalho em questão obteve êxito ao atingir sua meta primária, qual seja aplicar o ciclo PDCA em séries temporais, com o intuito de filtrar e transformar o ruído presente nos dados de sensoriamento remoto.

Os métodos utilizados evidenciaram uma notável habilidade na classificação dos alvos, com precisão elevada. Adicionalmente, a adoção de distintas regiões para treinamento, teste e validação suscitou uma avaliação qualitativa do desempenho, tanto do método PDCA-ST quanto do MNF.

A avaliação realizada no segundo capítulo deste estudo mostrou um desempenho elevado, porquanto os resultados da pesquisa apresentam mapas de identificação de florestas de mangue por meio dos quais é possível observar que o uso do método PDCA e MNF, empregando dados intercalados em um cubo temporal para as polarizações VV e VH, mostrou-se eficiente na classificação por meio dos algoritmos RF e KNN.

Essa nova abordagem na análise de dados SAR apresenta a transformação dos dados em frequência multicomponente, preservando as vantagens das duas polarizações, maximizando a

capacidade de classificação e, conseqüentemente, a detecção, o mapeamento e o monitoramento temporal das florestas de mangue - objetivo principal do estudo.

É oportuno destacar o uso alternado das polarizações VV e VH em um cubo temporal, facultando a complementaridade dos sinais recebidos pelo sensor. A utilização de ambas as polarizações permite uma análise mais abrangente, reduzindo os efeitos da polarização, que podem interferir na interação do sinal do radar com o meio natural, e modificar a polarização do sinal. A polarização dupla e cruzada minimiza esses efeitos, proporcionando uma análise mais precisa e confiável dos dados de sensoriamento remoto.

Nesse sentido, a utilização do método PDCA-MNF, em conjunto com as polarizações VV e VH, enseja uma boa diferenciação da vegetação e delimitação de florestas de mangue, como indicado pelos resultados alcançados.

Essa abordagem inovadora pode ser útil para outras aplicações de análise de dados SAR, em que a redução dos efeitos da polarização é fundamental para a obtenção de resultados mais precisos e confiáveis. Portanto, a utilização da polarização dupla e cruzada, aliada ao método PDCA-MNF, pode ser uma importante estratégia para a análise de dados SAR em outras aplicações de sensoriamento remoto.

No Capítulo 3, avaliaram-se três métodos de classificação neste estudo, sendo que o KNN obteve resultados superiores, em termos de qualidade das saídas de classificação e tempo computacional em todas as áreas de teste, conforme verificado pelas medidas gerais de precisão. O SVM apresentou desempenho menos preciso, especialmente em áreas com alta variabilidade intraclasse, ou quando as séries temporais anuais não se sobrepuseram aos ciclos fenológicos das culturas.

Quando comparado ao classificador RF, o KNN demonstrou resultados de classificação semelhantes em duas áreas de teste, enquanto o RF apresentou melhor desempenho na terceira, quando a heterogeneidade no campo era alta. Logo, o KNN provou ser mais robusto que o RF, ao lidar com diferentes números de amostras de treinamento.

Além disso, a segmentação automatizada de imagens multitemporais, utilizando os classificadores mencionados, permitiu um delineamento satisfatório das classes. Esses resultados indicam que o KNN é um método eficaz para a classificação de imagens multitemporais em aplicações de sensoriamento remoto, nomeadamente em áreas com alta variabilidade intraclasse, e para um número variado de amostras de treinamento.

Neste estudo, também, foram utilizadas séries temporais do Sentinel-2 que serviram como entrada de dados para o mapeamento e a classificação de áreas com florestas de mangue.

A análise foi aplicada em *pixels* e objetos em quatro áreas de teste, com diferentes resultados. Os três métodos de classificação utilizando o KNN, nas áreas de teste, em termos de qualidade das saídas de classificação e medidas pela métrica geral de precisão e de tempo computacional, superaram todos os testes de validação.

O SVM teve desempenho menos preciso, especialmente quando as classes mapeadas apresentaram alta variabilidade intraclasse, ou as séries temporais anuais não se sobrepuseram aos ciclos fenológicos das culturas. Quando comparado ao classificador de RF, o KNN obteve resultados de classificação semelhantes em duas áreas de teste. Por sua vez, o RF teve melhor desempenho no terceiro, onde no campo da heterogeneidade foi muito alto. Então, o KNN provou ser mais robusto que o RF, quando aplicado ao número de amostras de treinamento. A segmentação automatizada de imagens multitemporais usando os classificadores citados gerou um delineamento satisfatório das classes.

Dada a alta precisão de classificação obtida sem intervenção humana e o tempo computacional reduzido, o método KNN aplicado aos objetos integrados a programas operacionais, como o Abílio, nesta pesquisa voltada ao mapeamento e monitoramento de áreas litorâneas, tendo em vista a delimitação das coberturas das florestas de mangue, com base em séries temporais de imagens Sentinel-2, tem boa aplicabilidade.

Portanto, é meritório considerar a escolha do método de classificação adequado para cada aplicação, reputando as características do conjunto de dados, tais como a heterogeneidade da área, a sazonalidade e a quantidade de amostras de treinamento. A utilização de métodos de segmentação automatizados também pode ser uma abordagem eficiente para a análise de imagens multitemporais em aplicações de sensoriamento remoto.

O estudo atual concentrou-se em aplicar métodos para a delimitação e classificação de áreas de mangue a partir de imagens SAR e ópticas. No entanto, em pesquisas futuras, a metodologia pode ser aprimorada, por meio da inclusão de outros classificadores com vistas a aumentar a precisão, bem como pela abordagem de mudanças nos algoritmos utilizados.

Um desafio para futuras pesquisas é a classificação do tipo de uso do solo em áreas com cobertura excessiva de nuvens, e isso pode trazer benefícios significativos para o monitoramento dessas áreas. A mesma metodologia utilizada neste estudo pode ser aplicada para enfrentar esse desafio. Ademais, é possível explorar outras técnicas de processamento de imagens para melhorar a detecção ao longo do tempo, como a utilização de redes neurais profundas nas análises de séries temporais de imagens.

REFERÊNCIAS

AGUIAR, R. B. **Projeto cadastro de fontes de abastecimento por água subterrânea, Estado do Piauí**: diagnóstico do município de Ilha Grande. Fortaleza: CPRM - Serviço Geológico do Brasil, 2004.

AHMED, Nesar; GLASER, Marion. **Coastal aquaculture, mangrove deforestation and blue carbon emissions: is REDD+ a solution?** *Marine Policy*, [S. l.], v. 66, p. 58-66, abr. 2016. DOI <http://dx.doi.org/10.1016/j.marpol.2016.01.011>.

AKANNI, Adeniran; ONWUTEAKA, John; UWAGBAE, Michael; MULWA, Richard; ELEGBEDE, Isa Olalekan. The values of mangrove ecosystem services in the Niger Delta region of Nigeria. *The Political Ecology of Oil and Gas Activities in the Nigerian Aquatic Ecosystem*, [S. l.], p. 387-437, 2018. DOI <http://dx.doi.org/10.1016/b978-0-12-809399-3.00025-2>.

AL-NAJJAR, H. A. H.; KALANTAR, B.; PRADHAN, B.; SAEIDI, V.; HALIN, A. A.; UEDA, N.; MANSOR, S. Land cover classification from fused DSM and UAV images using convolutional neural networks. *Remote Sensing*, [S. l.], v. 11, n. 12, p. 1-18, 2019.

ALONGI, Daniel M. **Introduction in the energetics of mangrove forests**. Springer Science and Business Media BV, New York, 2009.

ALONGI, Daniel M. Present state and future of the world's mangrove forests. *Environmental Conservation*, [s.l.], v. 29, n. 03, p.331-349, set. 2002. Cambridge University Press (CUP). <http://dx.doi.org/10.1017/s0376892902000231>.

ANDERLE, Markus; KIRBY, Michael (ed.). An application of the maximum noise fraction method to filtering noisy timeseries. *In: MCWHIRTER, J. G.; PROUDLER, I. K. Proc. 5th International Conference on Mathematics in Signal Processing*. Coventry: University Of Warwick, 2001. cap. 9, p. 99-112.

ANNEBOINA, Lavanya Ravikanth; KUMAR, K.s. Kavi. Economic analysis of mangrove and marine fishery linkages in India. *Ecosystem Services*, [S. l.], v. 24, p. 114-123, abr. 2017. DOI <http://dx.doi.org/10.1016/j.ecoser.2017.02.004>.

ARAÚJO, Rayana Santos. **Classificação climatológica das nuvens precipitantes no nordeste brasileiro utilizando dados do radar a bordo de um satélite TRMM**. 2015. 129 f. Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.

ARGAMOSA, Reginald Jay Labadisos *et al.* Modelling above ground biomass of mangrove forest using Sentinel-1 imagery. *Isprs Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, [S. l.], v. -3, p. 13-20, abr. 2018. DOI <http://dx.doi.org/10.5194/isprs-annals-iv-3-13-2018>.

ATKINSON, Peter M.; NASER, David K. A Geostatistically Weightedk-NN Classifier for Remotely Sensed Imagery. 遥感影像的地统计加权k-NN分类器研究. **Geographical**

Analysis, [S. l.], v. 42, n. 2, p. 204-225, abr. 2010. DOI <http://dx.doi.org/10.1111/j.1538-4632.2010.00790.x>.

AWAD, M.; KHANNA, R. Machine learning. *In: Efficient Learning Machines*. Berkeley, CA: Apress, 2015. v. 66, p. 1-18.

BARBIER, Edward B. The protective service of mangrove ecosystems: A review of valuation methods. **Marine Pollution Bulletin**, [S. l.], v. 109, n. 2, p. 676-681, ago. 2016. DOI <http://dx.doi.org/10.1016/j.marpolbul.2016.01.033>.

BAUDRON, P.; ALONSO-SARRÍA, F.; GARCÍA-ARÓSTEGUI, J. L.; CÁNOVAS-GARCÍA, F.; MARTÍNEZ-VICENTE, D.; MORENO-BROTÓNS, J. Identifying the origin of groundwater samples in a multi-layer aquifer system with Random Forest classification. **Journal of Hydrology**, [S. l.], v. 499, p. 303-315, 2013.

BELGIU, Mariana; CSILLIK, Ovidiu. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing Of Environment**, [S.L.], v. 204, p. 509-523, jan. 2018. Elsevier BV. DOI <http://dx.doi.org/10.1016/j.rse.2017.10.005>.

BEN-DAVID, A. Comparison of classification accuracy using Cohen's Weighted Kappa. **Expert Systems with Applications**, [S. l.], v. 34, n. 2, p. 825-832, 2008.

BISHOP, Y. M.; HOLLAND, P. W.; FIENBERG, S. E. Discrete multivariate analysis theory and practice. **Discrete Multivariate Analysis Theory and Practice**, [S. l.], p. 1-557, 1975.

BLANKESPOOR, Brian; DASGUPTA, Susmita; LANGE, Glenn-marie. Mangroves as protection from storm surges in a changing climate. **Policy Research Working Papers**, [S. l.], p. 27-45, mar. 2016. DOI <http://dx.doi.org/10.1596/1813-9450-7596>.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 65, n. 1, p. 2-16, 2010.

BORGES, Jóina Freitas. **A história negada**: em busca de novos caminhos. 1. ed. Teresina: FUNDAPI, 2004. v. 1, 134 p.

BOSMA, Roel H. *et al.* Shrimp-based livelihoods in mangrove silvo-aquaculture farming systems. **Reviews In Aquaculture**, [S. l.], v. 8, n. 1, p. 43-60, set. 2014. DOI <http://dx.doi.org/10.1111/raq.12072>.

BOUILLON, Steven. Storage beneath mangroves. **Nature Geoscience**, [S.L.], v. 4, n. 5, p. 282-283, 3 abr. 2011. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/ngeo1130>.

BRASIL. Ministério do Meio Ambiente. Governo do Brasil. **Zona Costeira e Marinha**. 1998. Disponível em: <http://www.mma.gov.br/biodiversidade/biodiversidade-aquatica/zona-costeira-e-marinha>. Acesso em: 1 jan. 2017.

BREIMAN, L. **Manual**: setting up, using and understanding random forests V4.0. **הנושע עלון**, [S. l.], v. 66, p. 37-39, 2012.

- BREIMAN, Leo. **Random forests**. Machine Learning, [S. l.], v. 45, n. 1, p. 5-32, 2001. Springer Science and Business Media LLC. DOI <http://dx.doi.org/10.1023/a:1010933404324>.
- BROCKWELL, Peter J.; DAVIS, Richard A. **Stationary Time Series**. Springer Series In Statistics, [S.L.], p. 1-41, 1991. Springer New York. http://dx.doi.org/10.1007/978-1-4419-0320-4_1.
- CARDOSO, G. F.; SOUZA, C.; SOUZA-FILHO, P. W. M. Using spectral analysis of Landsat-5 TM images to map coastal wetlands in the Amazon River mouth, Brazil. **Wetlands Ecology and Management**, [S. l.], v. 22, n. 1, p. 79-92, 2014.
- CARVALHO JÚNIOR, O. A.; HERMUCHE, P. M.; GUIMARÃES, R. F. Identificação regional da floresta estacional decidual na bacia do rio Paraná a partir da análise multitemporal de imagens modis. **Revista Brasileira de Geofísica**, [S. l.], v. 24, n. 3, p. 319-332, 2006.
- CARVALHO JÚNIOR, O. A. de; SAMPAIO, C. da S.; SILVA, N. C. da; COUTO JÚNIOR, A. F.; GOMES, R. A. T.; CARVALHO, A. P. F. de; SHIMABUKURO, Y. E. Classificação de padrões de savana usando assinaturas temporais NDVI do sensor MODIS no Parque Nacional Chapada dos Veadeiros. **Revista Brasileira de Geofísica**, [S. l.], v. 26, n. 4, p. 505-517, 2008.
- CARVALHO JÚNIOR, O. A. de; SILVA, N. C. da; CARVALHO, A. P. F. de; COUTO JÚNIOR, A. F.; SILVA, C. R.; SHIMABUKURO, Y. E.; GUIMARÃES, R. F.; GOMES, R. A. T. Combining noise-adjusted principal components transform and median filter techniques for denoising MODIS temporal signatures. **Revista Brasileira de Geofísica**, [S. l.], v. 30, n. 2, p. 147-157, 2012.
- CARVALHO JÚNIOR, Osmar A. *et al.* A new approach to change vector analysis using distance and similarity measures. **Remote Sensing**, [S. l.], v. 3, n. 11, p. 2473-2493, nov. 2011. DOI <http://dx.doi.org/10.3390/rs3112473>.
- CARVALHO JÚNIOR, Osmar de *et al.* Probability density components analysis: a new approach to treatment and classification of SAR Images. **Remote Sensing**, [S. l.], v. 6, n. 4, p. 2989-3019, abr. 2014. DOI <http://dx.doi.org/10.3390/rs6042989>.
- CASTILLO, Jose Alan A. *et al.* Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 134, p. 70-85, dez. 2017. DOI <http://dx.doi.org/10.1016/j.isprsjprs.2017.10.016>.
- CEPRO. Fundação Centro de Pesquisa Econômica e Social do Piauí. **Macrozoneamento costeiro do Piauí**: relatório geoambiental e socioeconômico. Teresina, 1996.
- CHADWICK, J. Integrated LiDAR and IKONOS multispectral imagery for mapping mangrove distribution and physical properties. **International Journal of Remote Sensing**, [S. l.], v. 32, n. 21, p. 6765-6781, 2011.

CHEN, Bangqian *et al.* A mangrove forest map of China in 2015: analysis of time series landsat 7/8 and sentinel-1a imagery in google earth engine cloud computing platform. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S. l.], v. 131, p. 104-120, set. 2017. DOI <http://dx.doi.org/10.1016/j.isprsjprs.2017.07.011>.

CHOW, Jeffrey. Mangrove management for climate change adaptation and sustainable development in coastal zones. **Journal of Sustainable Forestry**, [S. l.], v. 37, n. 2, p. 139-156, jul. 2017. DOI <http://dx.doi.org/10.1080/10549811.2017.1339615>.

COHEN, Jacob. **A Coefficient of Agreement for Nominal Scales**. Educational and Psychological Measurement, [S. l.], v. 20, n. 1, p. 37-46, abr. 1960. DOI <http://dx.doi.org/10.1177/001316446002000104>.

CONGALTON, Russell G; GREEN, Kass. **Assesin a precisão de remotly detectados dados: principies and practices**. 2. ed. Boca Raton, London e New York: Taylor & Francis Group, 2009. 182 p.

COPERNICUS. **Application Domains**. Disponível em: <http://copernicus.eu/main/application-domains>, 2018. Acesso em: 30 out. 2018.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E.. Review Article Digital change detection methods in ecosystem monitoring: a review. **International Journal Of Remote Sensing**, [S.L.], v. 25, n. 9, p. 1565-1596, maio 2004. Informa UK Limited. <http://dx.doi.org/10.1080/0143116031000101675>.

CORCORAN, J. M.; KNIGHT, J. F.; GALLANT, A. L. Influence of multi-source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in northern Minnesota. **Remote Sensing**, [S. l.], v. 5, n. 7, p. 3212-3238, 2013.

COUTO JÚNIOR, Antonio Felipe; CARVALHO JUNIOR, Osmar Abílio de; MARTINS, Eder de Souza. Séries temporais MODIS aplicadas em sucessão de culturas de soja (*Glycine max* (L.) Merrill) e milho (*Zea mays* L.) em sistema de plantio direto. **Revista Brasileira de Cartografia**, v. 64, n. 3, p. 405-418, 2012. Disponível em: <<http://www.lsie.unb.br/rbc/index.php/rbc/article/view/423>>. Acesso em: 6 maio 2017.

COVER, T.; HART, P. Nearest neighbor pattern classification. **Ieee Transactions on Information Theory**, [S. l.], v. 13, n. 1, p. 21-27, jan. 1967. DOI <http://dx.doi.org/10.1109/tit.1967.1053964>.

CPRM. Companhia de Pesquisa de Recursos Minerais. **Mapa Geológico do Estado do Piauí**. Rio de Janeiro, 2003.

CRAFT, C. Mangroves. **Creating and Restoring Wetlands**. [S. l.]: Elsevier, 2016. p. 233-263.

CUTLER, D. R.; EDWARDS, T. C.; BEARD, K. H.; CUTLER, A.; KYLE, T.; GIBSON, J.; LAWLER, J. J.; BEARD, H.; HESS, T. Random Forests for Classification in Ecology Published by : Ecological Society of America. **Ecology**, [S. l.], v. 88, n. 11, p. 2783-2792, 2007.

- DAI, Aiguo; QIAN, Taotao; TRENBERTH, Kevin E.; MILLIMAN, John D. Changes in Continental Freshwater Discharge from 1948 to 2004. **Journal Of Climate**, [S.L.], v. 22, n. 10, p. 2773-2792, 15 maio 2009. American Meteorological Society. <http://dx.doi.org/10.1175/2008jcli2592.1>.
- DASGUPTA, Susmita *et al.* **Quantifying the protective capacity of mangroves from storm surges in coastal Bangladesh**. Plos One, [S. l.], v. 14, n. 3, p. 21-40, mar. 2019. DOI <http://dx.doi.org/10.1371/journal.pone.0214079>.
- DE VRIES, B.; PRINCIPE, J. C. The gamma model – A new neural model for temporal processing, **Neural Networks**, v. 5, p. 565-576, 1992.
- DE VRIES, B. **Temporal processing with neural networks** - the development of the gamma model. Tese (Doutorado em Ciência da Computação) – University of Florida, 1991.
- DENG, Z.; ZHU, X.; CHENG, D.; ZONG, M.; ZHANG, S. Efficient kNN classification algorithm for big data. **Neurocomputing**, [S. l.], v. 195, p. 143-148, 2016.
- DHINGRA, Sakshi; KUMAR, Dharminder. A review of remotely sensed satellite image classification. **International Journal of Electrical And Computer Engineering** (Ijece), [S.l.], v. 9, n. 3, p. 1720, jun. 2019. DOI <http://dx.doi.org/10.11591/ijece.v9i3.pp1720-1731>.
- DÍAZ-URIARTE, Ramón; ANDRÉS, Sara Alvarez de. Gene selection and classification of microarray data using random forest. **Bmc Bioinformatics**, [S. l.], v. 7, n. 1, p. 3-16, jan. 2006. DOI <http://dx.doi.org/10.1186/1471-2105-7-3>.
- DITTMAR, Thorsten *et al.* Mangroves, a major source of dissolved organic carbon to the oceans. **Global Biogeochemical Cycles**, [s.l.], v. 20, n. 1, p.30-40, 21 fev. 2006. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2005gb002570>.
- DOSTÁLOVÁ, Alena *et al.* Annual seasonality in Sentinel-1 signal for forest mapping and forest type classification. **International Journal of Remote Sensing**, [S. l.], v. 39, n. 21, p. 7738-7760, jun. 2018. DOI <http://dx.doi.org/10.1080/01431161.2018.1479788>.
- DONATO, Daniel C.; KAUFFMAN, J. Boone; MURDIYARSO, Daniel; KURNIANTO, Sofyan; STIDHAM, Melanie; KANNINEN, Markku. Mangroves among the most carbon-rich forests in the tropics. **Nature Geoscience**, [S.L.], v. 4, n. 5, p. 293-297, 3 abr. 2011. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/ngeo1123>.
- DRUSCH, M.; BELLO, U. del; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P. Sentinel-2: esa's optical high-resolution mission for gmes operational services. **Remote Sensing Of Environment**, [S. l.], v. 120, p. 25-36, May 2012. DOI <http://dx.doi.org/10.1016/j.rse.2011.11.026>.
- DUCART, D. F.; SILVA, A. M.; TOLEDO, C. L. B.; DE ASSIS, L. M. Mapping iron oxides with Landsat-8/OLI and EO-1/Hyperion imagery from the Serra Norte iron deposits in the Carajás Mineral Province, Brazil. **Brazilian Journal of Geology**, [S. l.], v. 46, n. 3, p. 331-349, 2016.
- DUTRA, V. A. B.; TAVARES, P. A.; RIBEIRO, H. M. C. Analysis of cloud condition on

Sentinel-2 MSI and Landsat-8 OLI images of a public supply lake in Belém-Pará-Brazil. **Ambiente e Agua - An Interdisciplinary Journal of Applied Science**, [S. l.], v. 14, n. 4, p. 1, 2019.

DUKE, N. C. et al. A World Without Mangroves? **Science**, [s.l.], v. 317, n. 5834, p.411-421, 6 jul. 2007. American Association for the Advancement of Science (AAAS). <http://dx.doi.org/10.1126/science.317.5834.41b>.

EL-REGAL, Mohamed A. Abu; IBRAHIM, Nesreen K. Role of mangroves as a nursery ground for juvenile reef fishes in the southern Egyptian Red Sea. **The Egyptian Journal of Aquatic Research**, [S. l.], v. 40, n. 1, p. 71-78, 2014. DOI <http://dx.doi.org/10.1016/j.ejar.2014.01.001>.

ELSAID, O.; ABDELKAREEM, A. Accuracy assessment of land use land cover in Umabdalla natural reserved forest, South Kordofan, Sudan. **International Journal of Agricultural and Environmental Sciences**, Cartum, v. 3, n. 1, p. 5-9, 2018.

EMBRAPA. **Solos**. Recife: UEP, 2006. Disponível em: www.uep.cnps.embrapa.br/solos/index.html. Acesso em: 28 dez. 2016.

ESA. European Space Agency. **History of Earth observation**. 2009. Disponível em: http://www.esa.int/SPECIALS/Eduspace_EN/SEM1NP3Z2OF_2.html. Acesso em: 30 out. 2018.

ESA, European Space Agency. **Radar**. 2014a. Disponível em: https://www.esa.int/SPECIALS/Eduspace_Global_/SEMIM5D6UQH_0.html. Acesso em: 22 nov. 2018.

ESA, European Space Agency. **Synthetic Aperture Radar (SAR)**. 2014b. Disponível em: https://www.esa.int/SPECIALS/Eduspace_Global/SEMF5D6UQH_2.html. Acesso em: 23 nov. 2018.

ESA. European Space Agency. **Sen2Cor Configuration and User Manual - Ref. S2-PDGS-MPC-L2A-SUM-V2.5.5**. [S. l.], 2018. p. 54.

ESA. European Space Agency. **Definitions**. 2019. Disponível em: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/definitions>. Acesso em: 4 abr. 2019.

FARIDAH-HANUM, I.; YUSOFF, F. M.; FITRIANTO, A.; AINUDDIN, N. A.; GANDASECA, S.; ZAITON, S.; NORIZAH, K.; NURHIDAYU, S.; ROSLAN, M. K.; HAKEEM, K. R.; SHAMSUDDIN, I.; ADNAN, I.; AWANG NOOR, A. G.; BALQIS, A. R. S.; RHYMA, P. P.; SITI AMINAH, I.; HILALUDDIN, F.; FATIN, R.; HARUN, N. Z. N. Development of a comprehensive mangrove quality index (MQI) in Matang Mangrove: Assessing mangrove ecosystem health. **Ecological Indicators**, [S. l.], v. 102, p. 103-117, 2019. DOI <http://dx.doi.org/10.1016/j.ecolind.2019.02.030>.

FERNÁNDEZ-BLANCO, E.; AGUIAR-PULIDO, V.; ROBERT MUNTEANU, C.; DORADO, J. Random forest classification based on star graph topological indices for antioxidant proteins. **Journal of Theoretical Biology**, [S. l.], v. 317, p. 331-337, 2013.

FERREIRA, A. C.; GANADE, G.; LUIZ DE ATAYDE, J. Restoration versus natural regeneration in a neotropical mangrove: effects on plant biomass and crab communities. **Ocean and Coastal Management**, [S. l.], v. 110, p. 38-45, 2015.

FIEUZAL, R.; BAUP, F. Estimation of leaf area index and crop height of sunflowers using multi-temporal optical and SAR satellite data. **International Journal of Remote Sensing**, [S. l.], p. 1-30, abr. 2016. DOI <http://dx.doi.org/10.1080/01431161.2016.1176276>.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. *In: XIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Anais [...]*. [S. l.], 2007. n. 1995, p. 5755-5762.

FIX E.; HODGES J. L. Discriminatory analysis - Nonparametric discrimination: consistency properties. **International Statistical Review**, v. 57, p. 238-247, 1951.

FLORES-DE-SANTIAGO, F.; KOVACS, J. M.; WANG, J.; FLORES-VERDUGO, F.; ZHANG, C.; GONZÁLEZ-FARÍAS, F. Examining the influence of seasonality, condition, and species composition on mangrove leaf pigment contents and laboratory based spectroscopy data. **Remote Sensing**, [S. l.], v. 8, n. 3, 2016.

FOODY, G. M. Harshness in image classification accuracy assessment. **International Journal of Remote Sensing**, [S. l.], v. 29, n. 11, p. 3137-3158, 2008. DOI <http://dx.doi.org/10.1080/01431160701442120>.

FOODY, G. M. Thematic map comparison. **Photogrammetric Engineering & Remote Sensing**, [S. l.], v. 70, n. 5, p. 627-633, 2013.

FRIESEN, Shantelle D.; DUNN, Christian; FREEMAN, Christopher. **Decomposition as a regulator of carbon accretion in mangroves: a review**. *Ecological Engineering*, [S. l.], v. 114, p. 173-178, abr. 2018. DOI <http://dx.doi.org/10.1016/j.ecoleng.2017.06.069>.

FRIESS, D. A.; WEBB, E. L. Variability in mangrove change estimates and implications for the assessment of ecosystem service provision. **Global Ecology and Biogeography**, [S. l.], v. 23, n. 7, p. 715-725, 2014.

FROST, V. S.; STILES, J. A.; SHANMUGAN, K. S.; HOLTZMAN, J. C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Trans. Pattern Analysis and Machine Intelligence*, v. 4, n. 2, p. 157-166, Mar. 1982. DOI [10.1109/tpami.1982.4767223](http://dx.doi.org/10.1109/tpami.1982.4767223).

FUKUNAGA, K.; NARENDRA, P. M. A branch and bound algorithm for computing k-Nearest Neighbors. **Ieee Transactions on Computers**, [S. l.], v. 24, n. 7, p. 750-753, jul. 1975. DOI <http://dx.doi.org/10.1109/t-c.1975.224297>.

GAN, M. A.; KOUSKY, V. E. **Um estudo observacional sobre as baixas frias da alta troposfera nas latitudes subtropicais do Atlântico Sul e Leste do Brasil**. São José dos Campos, SP: INPE, 1982.

GAO, Lianru *et al.* Optimized maximum noise fraction for dimensionality reduction of Chinese HJ-1A hyperspectral data. **Eurasip Journal on Advances in Signal Processing**, [S. l.], v. 2013, n. 1, p. 1-12, abr. 2013. DOI <http://dx.doi.org/10.1186/1687-6180-2013-65>.

GAO, Tian *et al.* Mapping spatial distribution of larch plantations from multi-seasonal Landsat-8 OLI imagery and multi-scale textures using random forests. **Remote Sensing**, [S. l.], v. 7, n. 2, p. 1702-1720, fev. 2015. DOI <http://dx.doi.org/10.3390/rs70201702>.

GENUER, Robin; POGGI, Jean-Michel; TULEAU-MALOT, Christine. Variable selection using random forests. **Pattern Recognition Letters**, [S. l.], v. 31, n. 14, p. 2225-2236, out. 2010. DOI <http://dx.doi.org/10.1016/j.patrec.2010.03.014>.

GHORBANIAN, Arsalan; MAGHSOUDI, Yasser; MOHAMMADZADEH, Ali. Clustering-based band selection using structural similarity index and entropy for hyperspectral image classification. **Traitement Du Signal**, [S. l.], v. 37, n. 5, p. 785-791, nov. 2020. DOI <http://dx.doi.org/10.18280/ts.370510>.

GHORBANIAN, Arsalan; MOHAMMADZADEH, Ali. An unsupervised feature extraction method based on band correlation clustering for hyperspectral image classification using limited training samples. **Remote Sensing Letters**, [S. l.], v. 9, n. 10, p. 982-991, ago. 2018. DOI <http://dx.doi.org/10.1080/2150704x.2018.1500723>.

GIORDAN, D.; NOTTI, D.; VILLA, A.; ZUCCA, F.; CALÒ, F.; PEPE, A.; DUTTO, F.; PARI, P.; BALDO, M.; ALLASIA, P. Low cost, multiscale and multi-sensor application for flooded area mapping. **Natural Hazards and Earth System Sciences**, [S. l.], v. 18, n. 5, p. 1493-1516, 2018.

GIRI, C. *et al.* Mangrove forest distributions and dynamics (1975–2005) of the tsunami-affected region of Asia. **Journal Of Biogeography**, [s.l.], v. 35, n. 3, p.519-528, mar. 2008. Wiley. <http://dx.doi.org/10.1111/j.1365-2699.2007.01806.x>.

GIRI, C. *et al.* Status and distribution of mangrove forests of the world using earth observation satellite data. **Global Ecology And Biogeography**, [s.l.], v. 20, n. 1, p.154-159, 17 ago. 2010. Wiley. <http://dx.doi.org/10.1111/j.1466-8238.2010.00584.x>.

GIRI, Chandra *et al.* Monitoring mangrove forest dynamics of the Sundarbans in Bangladesh and India using multi-temporal satellite data from 1973 to 2000. **Estuarine, Coastal And Shelf Science**, [s.l.], v. 73, n. 1-2, p.91-100, jun. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.ecss.2006.12.019>.

GILMAN, Eric L.; ELLISON, Joanna; DUKE, Norman C.; FIELD, Colin. Threats to mangroves from climate change and adaptation options: a review. **Aquatic Botany**, [S.L.], v. 89, n. 2, p. 237-250, ago. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.aquabot.2007.12.009>.

GODOY, Mario D.P.; LACERDA, Luiz D. de. Mangroves Response to Climate Change: A Review of Recent Findings on Mangrove Extension and Distribution. **Anais da Academia Brasileira de Ciências**, [s.l.], v. 87, n. 2, p.651-667, 15 maio 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0001-3765201520150055>.

GRANDONI. **Advantages and limitations of using satellite images for flood mapping, Workshop on the use of the Copernicus Emergency Service for Floods, Brussels, available.** 2013. Disponível em: http://www.copernicus.eu/sites/default/files/documents/User_uptake/Emergency_Events/Athens/03_Session_01_AdvantageAndLimitationsOfUsingSatelliteImagery.pdf. Acesso em: 30 out. 2018.

GREEN, A. A.; BERMAN, M.; SWITZER, P.; CRAIG, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 26, n. 1, p. 65-74, 1988. DOI <http://dx.doi.org/10.1109/36.3001>.

GUERRA, Maria Daniely Freire. **A problemática da desertificação nos sertões do médio Jaguaribe, Ceará: o contexto do município de Jaguaribe.** 2009. 171 f. Dissertação (Mestrado em Geografia) – Universidade Estadual do Ceará, Fortaleza, 2009.

GUO, Meng; LI, Jing; SHENG, Chunlei; XU, Jiawei; WU, Li. A Review of Wetland Remote Sensing. **Sensors**, [S.L.], v. 17, n. 4, p. 777, 5 abr. 2017. MDPI AG. DOI <http://dx.doi.org/10.3390/s17040777>.

HALDAR, Dipanwita *et al.* Time series analysis of co-polarization phase difference (PPD) for winter field crops using polarimetric C-band SAR data. **International Journal Of Remote Sensing**, [S. l.], v. 37, n. 16, p. 3753-3770, jul. 2016. DOI <http://dx.doi.org/10.1080/01431161.2016.1204024>.

HEENKENDA, M. K.; JOYCE, K. E.; MAIER, S. W.; BARTOLO, R. Mangrove species identification: Comparing WorldView-2 with aerial photographs. **Remote Sensing**, [S. l.], v. 6, n. 7, p. 6064-6088, 2014.

HEENKENDA, M. K.; JOYCE, K. E.; MAIER, S. W.; DE BRUIN, S. Quantifying mangrove chlorophyll from high spatial resolution imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 108, p. 234-244, 2015.

HEUMANN, B. W. An object-based classification of mangroves using a hybrid decision tree-support vector machine approach. **Remote Sensing**, [S. l.], v. 3, n. 11, p. 2440-2460, 2011b.

HEUMANN, B. W. Satellite remote sensing of mangrove forests: Recent advances and future opportunities. **Progress in Physical Geography**, [S. l.], v. 35, n. 1, p. 87-108, 2011a.

HEUPEL, K.; SPENGLER, D.; ITZEROTT, S. A progressive crop-type classification using multitemporal remote sensing data and phenological information. **PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science**, [S. l.], v. 86, n. 2, p. 53-69, 2018.

HO, Tin Kam. **Random decision forests.** Proceedings of 3rd International Conference on Document Analysis and Recognition, [S. l.], p. 278-282, ago. 1995. DOI <http://dx.doi.org/10.1109/icdar.1995.598994>.

HO, Tin Kam. **The random subspace method for constructing decision forests.** Ieee Transactions on Pattern Analysis and Machine Intelligence, [S. l.], v. 20, n. 8, p. 832-844, 1998. DOI <http://dx.doi.org/10.1109/34.709601>.

HOGARTH, P. J. Mangrove ecosystems. **Reference Module in Life Sciences**. [S. l.]: Elsevier, 2017. v. 1, p. 2019.

HONG, Gang *et al.* Integration of optical and Synthetic Aperture Radar (SAR) images to differentiate grassland and alfalfa in Prairie area. *International Journal of Applied Earth Observation and Geoinformation*, [S. l.], v. 28, p. 12-19, May 2014. DOI <http://dx.doi.org/10.1016/j.jag.2013.10.003>.

HU, L. Y.; HUANG, M. W.; KE, S. W.; TSAI, C. F. The distance function effect on k-nearest neighbor classification for medical datasets. **SpringerPlus**, [S. l.], v. 5, n. 1, 2016.

HU, Qing-hua; YU, Da-ren; WANG, Ming-yang. Constructing rough decision forests. **Lecture Notes in Computer Science**, [S. l.], p. 147-156, 2005. DOI http://dx.doi.org/10.1007/11548706_16.

HUANG, Shengli *et al.* Fusing optical and radar data to estimate sagebrush, herbaceous, and bare ground cover in Yellowstone. **Remote Sensing of Environment**, [S. l.], v. 114, n. 2, p. 251-264, fev. 2010. DOI <http://dx.doi.org/10.1016/j.rse.2009.09.013>.

HUANG, T.; YANG, G.; TANG, G. **A fast two-dimensional median filtering algorithm**. *Ieee Transactions on Acoustics, Speech, And Signal Processing*, [S. l.], v. 27, n. 1, p. 13-18, fev. 1979. DOI <http://dx.doi.org/10.1109/tassp.1979.1163188>.

HUNG, Vu Manh; TIEN, Dam Duc; VAN LUONG, Cao. **Carbon sequestration potential in mangrove forests in hai phong coastal areas**. *Tạp Chí Khoa Học Và Công Nghệ Biển*, [S. l.], v. 15, n. 4, p. 9-15, nov. 2015. DOI <http://dx.doi.org/10.15625/1859-3097/15/4/7379>.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Macrozoneamento geoambiental da Bacia Hidrográfica do Rio Parnaíba**. Rio de Janeiro: IBGE, 1996. (Série de Estudos e Pesquisas em Geociências, n. 04).

IBGE. Instituto Brasileiro de Geografia e Estatística. **População residente – Estudo de estimativas populacionais por município, 1980 – 2015**. 2018.

IKIEL, C.; USTAOGU, B.; DUTUCU, A. A.; KILIC, D. E. Remote sensing and GIS-based integrated analysis of land cover change in Duzce plain and its surroundings (north western Turkey). **Environmental Monitoring and Assessment**, [S. l.], v. 185, n. 2, p. 1699-1709, 2013.

JENSEN, J. **Introductory digital image processing: a remote sensing perspective**. Pearson Prentice Hall, Upper Saddle River, 2005. p. 526.

JENNERJAHN, Tim C.; ITTEKKOT, Venugopalan. Relevance of mangroves for the production and deposition of organic matter along tropical continental margins. **Naturwissenschaften**, [s.l.], v. 89, n. 1, p.23-30, jan. 2002. Springer Nature. <http://dx.doi.org/10.1007/s00114-001-0283-x>.

KOVACS, J. M.; SANTIAGO, F. F. De; BASTIEN, J.; LAFRANCE, P. An assessment of mangroves in Guinea, West Africa, using a field and remote sensing based approach. **Wetlands**, [S. l.], v. 30, n. 4, p. 773-782, 2010.

- KOVACS, J. M.; WANG, J.; FLORES-VERDUGO, F. Mapping mangrove leaf area index at the species level using IKONOS and LAI-2000 sensors for the Agua Brava Lagoon, Mexican Pacific. **Estuarine, Coastal and Shelf Science**, [S. l.], v. 62, n. 1-2, p. 377-384, 2005.
- KOMIYAMA, Akira; ONG, Jin Eong; POUNGPARN, Sasitorn. Allometry, biomass, and productivity of mangrove forests: A review. **Aquatic Botany**, [s.l.], v. 89, n. 2, p.128-137, ago. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.aquabot.2007.12.006>.
- KRISTENSEN, Erik *et al.* Organic carbon dynamics in mangrove ecosystems: A review. **Aquatic Botany**, [S. l.], v. 89, n. 2, p. 201-219, ago. 2008. DOI <http://dx.doi.org/10.1016/j.aquabot.2007.12.005>.
- KUAN, D. T.; SAWCHUK, A. A.; STRAND, T. C.; CHAVEL, P. Adaptive noise smoothing filter for images with signal-dependent noise. **IEEE Trans. Pattern Analysis and Machine Intelligence**, v. PAMI 7, n. 2, Mar. 1985. DOI <http://dx.doi.org/10.1109/tpami.1985.4767641>.
- KUENZER, Claudia *et al.* Remote sensing of mangrove ecosystems: a review. **Remote Sensing**, [S. l.], v. 3, n. 5, p. 878-928, abr. 2011. DOI <http://dx.doi.org/10.3390/rs3050878>.
- KUENZER, Claudia *et al.* Remote Sensing of River Delta Inundation: Exploiting the Potential of Coarse Spatial Resolution, Temporally-Dense MODIS Time Series. **Remote Sensing**, [s.l.], v. 7, n. 7, p.8516-8542, 6 jul. 2015. MDPI AG. <http://dx.doi.org/10.3390/rs70708516>.
- KUMAR, P. *et al.* Estimation of winter wheat crop growth parameters using time series Sentinel-1A SAR data. **Geocarto International**, [S. l.], v. 33, n. 9, p. 942-956, abr. 2017. DOI <http://dx.doi.org/10.1080/10106049.2017.1316781>.
- LEBOURGEOIS, V.; DUPUY, S.; VINTROU, É.; AMELINE, M.; BUTLER, S.; BÉGUÉ, A. A combined random forest and OBIA classification scheme for mapping smallholder agriculture at different nomenclature levels using multisource data (simulated Sentinel-2 time series, VHRS and DEM). **Remote Sensing**, [S. l.], v. 9, n. 3, p. 1-20, 2017.
- LEE, Jong-Sen. Digital image smoothing and the sigma filter. **Computer Vision, Graphics, and Image Processing**, [S.L.], v. 24, n. 2, p. 255-269, nov. 1983. DOI [http://dx.doi.org/10.1016/0734-189x\(83\)90047-6](http://dx.doi.org/10.1016/0734-189x(83)90047-6).
- LEE, Jong-Sen; WEN, Jen-Hung; AINSWORTH, T.L.; CHEN, Kun-Shan; CHEN, A.J. Improved Sigma Filter for Speckle Filtering of SAR Imagery. **IEEE Transactions On Geoscience and Remote Sensing**, [S.L.], v. 47, n. 1, p. 202-213, jan. 2009. DOI <http://dx.doi.org/10.1109/tgrs.2008.2002881>.
- LI, J.; ROY, D. P. A global analysis of Sentinel-2a, Sentinel-2b and Landsat-8 data revisit intervals and implications for terrestrial monitoring. **Remote Sensing**, [S. l.], v. 9, n. 9, 2017.
- LIAW, Andy *et al.* Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18-22, 2003

- LIAW, Andy; WIENER, Matthew. Classification and Regression by random Forest. **R News**, Vienna, v. 3, n. 2, p. 18-22, dez. 2002. Disponível em: https://www.r-project.org/doc/Rnews/Rnews_2002-3.pdf. Acesso em: 6 maio 2019.
- LIPING, C.; YUJUN, S.; SAEED, S. Monitoring and predicting land use and land cover changes using remote sensing and GIS techniques - A case study of a hilly area, Jiangle, China. **PLoS ONE**, [S. l.], v. 13, n. 7, p. 1-23, 2018.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, [S. l.], v. 14, n. 2, p. 43-67, 2007. DOI <http://dx.doi.org/10.22456/2175-2745.5690>.
- LUCAS, Richard; REBELO, Lisa-Maria; FATOYINBO, Lola; ROSENQVIST, Ake; ITOH, Takuya; SHIMADA, Masanobu; SIMARD, Marc; SOUZA-FILHO, Pedro Walfir; THOMAS, Nathan; TRETTIN, Carl. Contribution of L-band SAR to systematic global mangrove monitoring. **Marine And Freshwater Research**, [S.L.], v. 65, n. 7, p. 589, 2014. CSIRO Publishing. <http://dx.doi.org/10.1071/mf13177>.
- MACIEL, L. M. M. **Processamento de imagens ALOS/PALSAR aplicado à regularização fundiária na Amazônia**. 2012. 94 f. Dissertação (Mestrado em Geografia) – Universidade de Brasília (UnB), Brasília, 2012.
- MAILLO, J.; GARCIA, S.; LUENGO, J.; HERRERA, F.; TRIGUERO, I. Fast and scalable approaches to accelerate the fuzzy k nearest neighbors classifier for Big Data. **IEEE Transactions on Fuzzy Systems**, [S. l.], v. 6706, n. c, p. 1, 2019.
- MANNA, Sudip; RAYCHAUDHURI, Barun. Mapping distribution of Sundarban mangroves using Sentinel-2 data and new spectral metric for detecting their health condition. **Geocarto International**, [S. l.], v. 35, n. 4, p. 434-452, dez. 2018. DOI <http://dx.doi.org/10.1080/10106049.2018.1520923>.
- MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. **An Introduction to Information Retrieval**. Cambridge ed. Chichester, UK: online edition, 2009.
- MARQUES, Jorge Bohrer *et al.* Classificação da cobertura da terra na região da ilha do Bananal usando imagens multitemporais PALSAR-2/ALOS-2. **Confins**, [S. l.], n. 39, p. 21-40, mar. 2019. DOI <http://dx.doi.org/10.4000/confins.17506>.
- MARTIN, T. S. H.; OLDS, A. D.; PITT, K. A.; JOHNSTON, A. B.; BUTLER, I. R.; MAXWELL, P. S.; CONNOLLY, R. M. Effective protection of fish on inshore coral reefs depends on the scale of mangrove - reef connectivity. **Marine Ecology Progress Series**, [S. l.], v. 527, n. 2015, p. 157-165, 2015.
- MCCARTHY, M. J.; MERTON, E. J.; MULLER-KARGER, F. E. Improved coastal wetland mapping using very-high 2-meter spatial resolution imagery. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 40, p. 11-18, 2015.
- MCNEMAR, Q. Note on the sampling error of the difference between correlated proportions or percentages. **Psychometrika**, [S. l.], v. 12, n. 2, p. 153-157, 1947.

MOMENI, R.; APLIN, P.; BOYD, D. S. Mapping complex urban land cover from spaceborne imagery: the influence of spatial resolution, spectral band set and classification approach. **Remote Sensing**, [S. l.], v. 8, n. 2, 2016.

MONDAL, Pinki; LIU, Xue; FATOYINBO, Temilola E.; LAGOMASINO, David. Evaluating combinations of Sentinel-2 Data and machine-learning algorithms for mangrove mapping in west Africa. **Remote Sensing**, [S. l.], v. 11, n. 24, p. 2928, dez. 2019. DOI <http://dx.doi.org/10.3390/rs11242928>.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 66, n. 3, p. 247-259, 2011.

MUKHERJEE, N.; SUTHERLAND, W. J.; DICKS, L.; HUGÉ, J.; KOEDAM, N.; DAHDOUH-GUEBAS, F. Ecosystem service valuations of mangrove ecosystems to inform decision making and future valuation exercises. **PLoS ONE**, [S. l.], v. 9, n. 9, p. 1-9, 2014.

MÜLLER-WILM, U. Sen2Cor configuration and user manual, Ref. S2-PDGS-MPC-L2A-SUM-V2.3. **European Space Agency**, [S. l.], 2016.

NABABA, Iliya; SYMEONAKIS, Elias; KOUKOULAS, Sotirios; HIGGINBOTTOM, Thomas; CAVAN, Gina; MARSDEN, Stuart. Land Cover Dynamics and Mangrove Degradation in the Niger Delta Region. **Remote Sensing**, [S. l.], v. 12, n. 21, p. 3619, nov. 2020. DOI <http://dx.doi.org/10.3390/rs12213619>.

NAVARRO, José Antonio *et al.* Integration of UAV, Sentinel-1, and Sentinel-2 Data for mangrove plantation aboveground biomass monitoring in Senegal. **Remote Sensing**, [S. l.], v. 11, n. 1, p. 77-88, jan. 2019. DOI <http://dx.doi.org/10.3390/rs11010077>.

NASDA, National Space Development Agency Of Japan. **Remote Sensing Notes**. 1999. Disponível em: <http://sar.kangwon.ac.kr/etc/rs_note/index.htm>. Acesso em: 22 nov. 2018

NIGSCH, F.; BENDER, A.; VANBUUREN, B.; TISSEN, J.; NIGSCH, E.; MITCHELL, J. B. O. Melting point prediction employing k-nearest neighbor algorithms and genetic parameter optimization. **Journal of Chemical Information and Modeling**, [S. l.], v. 46, n. 6, p. 2412-2422, 2006.

NINGTHOUJAM, Ramesh *et al.* Mapping Forest Cover and Forest Cover Change with Airborne S-Band Radar. **Remote Sensing**, [S. l.], v. 8, n. 7, p. 577-598, jul. 2016. DOI <http://dx.doi.org/10.3390/rs8070577>.

NUNES, Odilon. **Pesquisas para a História do Piauí**. 2. ed. Rio de Janeiro: Artenova S.A., 1975. v. 01, p. 30.

PAHLEVAN, N.; SARKAR, S.; FRANZ, B.A.; BALASUBRAMANIAN, S.V.; HE, J. Sentinel-2 MultiSpectral Instrument (MSI) data processing for aquatic science applications: demonstrations and validations. **Remote Sensing Of Environment**, [S. l.], v. 201, p. 47-56, nov. 2017. DOI <http://dx.doi.org/10.1016/j.rse.2017.08.033>.

PFLUGMACHER, Dirk. Moderate resolution remote sensing alternatives: a review of Landsat-like sensors and their applications. **Journal Of Applied Remote Sensing**, [S. l.], v. 1, n. 1, p. 012506-012522, nov. 2007. DOI <http://dx.doi.org/10.1117/1.2819342>.

PHAM, T. D.; YOSHINO, K.; LE, N. N.; BUI, D. T. Estimating aboveground biomass of a mangrove plantation on the Northern coast of Vietnam using machine learning techniques with an integration of ALOS-2 PALSAR-2 and Sentinel-2A data. **International Journal of Remote Sensing**, [S. l.], v. 00, n. 00, p. 1-28, 2018.

POÇAS, Jansen Santos. **Avaliação dos espectros de onda obtidos por radar de abertura sintética (SAR) para os litorais de Florianópolis/SC e Rio Grande/RS / Jansen Santos Poças**. 2011. 143 f. Dissertação (Mestrado) - Curso de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.

QUANG, Nguyen Hong; QUINN, Claire H.; STRINGER, Lindsay C.; CARRIE, Rachael; HACKNEY, Christopher R.; VANHUE, Le Thi; VAN TAN, Dao; NGA, Pham Thi Thanh. Multi-decadal changes in mangrove extent, age and species in the red river estuaries of Viet Nam. **Remote Sensing**, [S. l.], v. 12, n. 14, p. 2289, jul. 2020. DOI <http://dx.doi.org/10.3390/rs12142289>.

RAJAH, Perushan; ODINDI, John; MUTANGA, Onesimo. Feature level image fusion of optical imagery and Synthetic Aperture Radar (SAR) for invasive alien plant species detection and mapping. **Remote Sensing Applications: society and environment**, [S. l.], v. 10, p. 198-208, abr. 2018. DOI <http://dx.doi.org/10.1016/j.rsase.2018.04.007>.

RAYEGANI, Behzad; BARATI, Susan; GOSHTASB, Hamid; SARKHEIL, Hamid; RAMEZANI, Javad. An effective approach to selecting the appropriate pan-sharpening method in digital change detection of natural ecosystems. **Ecological Informatics**, [S. l.], v. 53, p. 100984, set. 2019. DOI <http://dx.doi.org/10.1016/j.ecoinf.2019.100984>.

RODRÍGUEZ, Efrén Castro; LUNA, Iván León; HERNÁNDEZ, José Pinedo. Biogeochemistry of mangrove sediments in the Swamp of Mallorquin, Colombia. **Regional Studies in Marine Science**, [S. l.], v. 17, p. 38-46, jan. 2018. DOI <http://dx.doi.org/10.1016/j.rsma.2017.11.005>.

ROMAÑACH, Stephanie S. *et al.* Conservation and restoration of mangroves: global status, perspectives, and prognosis. **Ocean & Coastal Management**, [S. l.], v. 154, p. 72-82, mar. 2018. DOI <http://dx.doi.org/10.1016/j.ocecoaman.2018.01.009>.

ROSLANI, M. A.; MUSTAPHA, M. A.; LIHAN, T.; JULIANA, W. A. Wan. Classification of mangroves vegetation species using texture analysis on Rapideye satellite imagery. **Aip Conference Proceedings**, [S. l.], v. 1571, n. 101063/14858701, p. 480-486, 31 dez. 2013. DOI <http://dx.doi.org/10.1063/1.4858701>.

RÜETSCHI, Marius; SCHAEPMAN, Michael E.; SMALL, David. Using multitemporal Sentinel-1 C-band backscatter to monitor phenology and classify deciduous and Coniferous Forests in Northern Switzerland. **Remote Sensing**, [S. l.], v. 10, n. 2, p. 55-85, dez. 2017. DOI <http://dx.doi.org/10.3390/rs10010055>.

SAINTILAN, N.; WILSON, N. C.; ROGERS, K.; RAJKARAN, A.; KRAUSS, K. W.

Mangrove expansion and salt marsh decline at mangrove poleward limits. **Global Change Biology**, [S. l.], v. 20, n. 1, p. 147-157, 2014.

SALK, C.; FRITZ, S.; SEE, L.; DRESEL, C.; MCCALLUM, I. An exploration of some pitfalls of thematic map assessment using the new map tools resource. **Remote Sensing**, [S. l.], v. 10, n. 3, p. 1-14, 2018.

SANDBERG, Monica. **Land cover mapping with multi-temporal SAR and optical satellite data**. 2016. 81 f. Dissertação (Mestrado em Geomática) – Department of Built Environment, School of Engineering, Aalto University, Espoo, 2016.

SANTIAGO, F. F. de; KOVACS, J. M.; LAFRANCE, P. An object-oriented classification method for mapping mangroves in Guinea, West Africa, using multipolarized ALOS PALSAR L-band data. **International Journal of Remote Sensing**, [S. l.], v. 34, n. 2, p. 563-586, 2013.

SATPATHY, Rajat; SINGH, Vivek Kumar; PARVEEN, Reshma; JEYASEELAN, A. T. Spectral Analysis of Hyperion Data for Mapping the Spatial Variation of in a Part of Latehar & Gumla District, Jharkhand. *Journal Of Geographic Information System*, [S.L.], v. 02, n. 04, p. 210-214, 2010. **Scientific Research Publishing**, Inc. DOI <http://dx.doi.org/10.4236/jgis.2010.24029>.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, [S. l.], v. 36, n. 8, p. 1627-1639, 1964.

SCHMITT, Michael; TUPIN, Florence; ZHU, Xiao Xiang. Fusion of SAR and optical remote sensing data — Challenges and recent trends. 2017 Ieee International Geoscience And **Remote Sensing Symposium (IGARSS)**, [S. l.], p. 27-40, jul. 2017. DOI <http://dx.doi.org/10.1109/igarss.2017.8128239>.

SIDHU, N.; PEBESMA, E.; CÂMARA, G. Using Google Earth Engine to detect land cover change: Singapore as a use case. **European Journal of Remote Sensing**, [S. l.], v. 51, n. 1, p. 486-500, 2018.

SILVA, Marcos Pereira da. **Categorias geoambientais da paisagem costeira de Ilha Grande-PI**. 2013. 133 f. Dissertação (Mestrado em Geografia) – Universidade Federal de Sergipe, São Cristóvão, 2013. Cap. 07.

SILVA, Miriam Rodrigues da. **Uso de séries temporais do sensor MODIS para identificar diferentes culturas agrícolas**. 2018. 109 f. Tese (Doutorado em Geografia) – Universidade de Brasília, Brasília, 2018. Cap. 4.

SILVA, Miriam Rodrigues da *et al.* Wheat planted area detection from the MODIS NDVI time series classification using the nearest neighbor method calculated by the Euclidean distance and cosine similarity measures. **Geocarto International**, [S. l.], p. 1-15, fev. 2019. DOI <http://dx.doi.org/10.1080/10106049.2019.1581266>.

SILVEIRA, J. D. da. Morfologia do litoral. In: AZEVEDO, Aroldo de (Ed.). **Brasil: a terra e o homem**. São Paulo: Companhia Editora Nacional, 1964. p. 253-305.

- SON, Nguyen-thanh *et al.* **Assessment of Sentinel-1A data for rice crop classification using random forests and support vector machines.** Geocarto International, [S. l.], p. 1-15, fev. 2017. DOI <http://dx.doi.org/10.1080/10106049.2017.1289555>.
- SOARES, Vicente Paulo; HOFFER, Roger Milton. **Detecção de mudanças em povoados de Eucalyptus spp e outros usos da terra através de imagens TM/Landsat-5 na região do Vale do Rio Doce-MG.** *Árvore*, Viçosa, v. 20, n. 1, p.117-127, 04 dez. 1995.
- SPALDING, M; BLASCO, F; FIELD, CD. **World atlas of mangrove.** The International Society for Mangrove Ecosystems, Okinawa, Japan,1997. 178 p
- STEELE, B. M.; REDMOND, R. L. A method of exploiting spatial information for improving classification rules: application to the construction of polygon-based land cover maps. **International Journal of Remote Sensing**, [S. l.], v. 22, n. 16, p. 3143-3166, jan. 2001. DOI <http://dx.doi.org/10.1080/01431160152558297>.
- STEELE-DUNNE, Susan C. *et al.* Radar remote sensing of agricultural canopies: a review. *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, [S. l.], v. 10, n. 5, p. 2249-2273, maio 2017. DOI <http://dx.doi.org/10.1109/jstars.2016.2639043>.
- STEHMAN, Stephen V. Estimating the Kappa Coefficient and its Variance under Stratified Random Sampling. **Photogrammetric Engineering & Remote Sensing**, [S. l.], v. 62, n. 4, p. 401-407, abr. 1996.
- SUDMANN, M.; TIEDE, D.; AUGUSTIN, H.; LANG, S. Assessing global Sentinel-2 coverage dynamics and data availability for operational Earth Observation (EO) applications using the EO-Compass. **International Journal of Digital Earth**, [S. l.], v. 0, n. 0, p. 1-17, 2019.
- SUGUIO, K.; MARTIN, L.; BITTENCOURT, A. C. S. P.; DOMINGUEZ, J. M. L.; FLEXOR, J. M.; AZEVEDO, A. E. G. Flutuações do nível relativo do mar durante o quaternário superior ao longo do litoral brasileiro e suas implicações na sedimentação costeira. **Revista Brasileira de Geociências**, São Paulo, SP, v. 15, 1985.
- TEODORO, A. C. M.; BELTRÃO, N. **Evaluating the potential of Sentinel-2 MSI and Landsat-8 OLI data fusion for land cover mapping in Brazilian Amazon**, [S. l.], p. 7, Oct. 2018.
- THOMAS, Nathan *et al.* An approach to monitoring mangrove extents through time-series comparison of JERS-1 SAR and ALOS PALSAR data. **Wetlands Ecology and Management**, [S. l.], v. 23, n. 1, p. 3-17, ago. 2014. DOI <http://dx.doi.org/10.1007/s11273-014-9370-6>.
- THOMAS, Nathan *et al.* Distribution and drivers of global mangrove forest change, 1996–2010. **Plos One**, [s.l.], v. 12, n. 6, p.179-302, 8 jun. 2017. Public Library of Science (PLoS). <http://dx.doi.org/10.1371/journal.pone.0179302>.
- TIAN, Haifeng *et al.* Mapping early, middle and late rice extent using Sentinel-1A and Landsat-8 Data in the Poyang Lake Plain, China. **Sensors**, [S. l.], v. 18, n. 2, p. 1-15, jan. 2018. DOI <http://dx.doi.org/10.3390/s18010185>.

TOOSI, Neda Bihamta; SOFFIANIAN, Ali Reza; FAKHERAN, Sima; POURMANAFI, Saeid; GINZLER, Christian; WASER, Lars T. Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. **Global Ecology and Conservation**, [S. l.], v. 19, p. 62-85, jul. 2019. DOI <http://dx.doi.org/10.1016/j.gecco.2019.e00662>.

TORBICK, Nathan *et al.* Monitoring Rice Agriculture across Myanmar Using Time Series Sentinel-1 Assisted by Landsat-8 and PALSAR-2. **Remote Sensing**, [S. l.], v. 9, n. 2, p. 119-138, fev. 2017. DOI <http://dx.doi.org/10.3390/rs9020119>.

TORRES, Ramon *et al.* GMES Sentinel-1 mission. **Remote Sensing of Environment**, [S. l.], v. 120, p. 9-24, maio 2012. DOI <http://dx.doi.org/10.1016/j.rse.2011.05.028>.

TUKEY, John W. Exploratory data analysis. **Biometrical Journal**, [S. l.], v. 23, n. 4, p. 413-414, 1977. DOI <http://dx.doi.org/10.1002/bimj.4710230408>.

TWELE, André *et al.* Sentinel-1-based flood mapping: a fully automated processing chain. **International Journal of Remote Sensing**, [S. l.], v. 37, n. 13, p. 2990-3004, jun. 2016. DOI <http://dx.doi.org/10.1080/01431161.2016.1192304>.

UDDIN, K.; MATIN, M. A.; MEYER, F. J. Operational flood mapping using multi-temporal Sentinel-1 SAR images: a case study from Bangladesh. **Remote Sensing**, [S. l.], v. 11, n. 13, 2019.

UNIÃO EUROPEIA. **Copernicus**: Sentinel-1 – The SAR Imaging constellation for land and ocean services. Copernical the space professional network. 2018. Disponível em: <https://www.copernical.com/projects-public/item/18245-copernicus-sentinel-1-the-sar-imaging-constellation-for-land-and-ocean-services>. Acesso em: 28 jun. 2021.

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

VAN BEIJMA, S.; COMBER, A.; LAMB, A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. **Remote Sensing of Environment**, [S. l.], v. 149, p. 118-129, 2014.

VAN BOCHOVE, J.; SULLIVAN, E.; NAKAMURA, T. **The Importance of Mangroves to People: A Call to Action** (Cambridge: UNEP). 2014.

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, p. 106-115, 2010. DOI: 10.1016/j.rse.2009.08.014.

VO, Quoc Tuan *et al.* Review of valuation methods for mangrove ecosystem services. **Ecological Indicators**, [S. l.], v. 23, p. 431-446, dez. 2012. DOI <http://dx.doi.org/10.1016/j.ecolind.2012.04.022>.

WALTERS, B. B.; RÖNNBÄCK, P.; KOVACS, J. M.; CRONA, B.; HUSSAIN, S. A.; BADOLA, R.; PRIMAVERA, J. H.; BARBIER, E.; DAHDOUH-GUEBAS, F. Ethnobiology,

- socio-economics and management of mangrove forests: a review. **Aquatic Botany**, [S. l.], v. 89, n. 2, p. 220-236, 2008.
- WANG, Le; JIA, Mingming; YIN, Dameng; TIAN, Jinyan. A review of remote sensing for mangrove forests: 1956-2018. **Remote Sensing of Environment**, [S. l.], v. 231, p. 111223, set. 2019. DOI <http://dx.doi.org/10.1016/j.rse.2019.111223>.
- WANG, Y.; YANG, M.; WEI, G.; HU, R.; LUO, Z.; LI, G. Improved PLS regression based on SVM classification for rapid analysis of coal properties by near-infrared reflectance spectroscopy. **Sensors and Actuators, B: Chemical**, [S. l.], v. 193, p. 723-729, 2014.
- WASKE, B.; LINDEN, S. van Der. Classifying Multilevel Imagery From SAR and Optical Sensors by Decision Fusion. **Ieee Transactions on Geoscience and Remote Sensing**, [S. l.], v. 46, n. 5, p.1457-1466, maio 2008. DOI <http://dx.doi.org/10.1109/tgrs.2008.916089>.
- WHELEN, Tracy; SIQUEIRA, Paul. Time-series classification of Sentinel-1 agricultural data over North Dakota. **Remote Sensing Letters**, [S. l.], v. 9, n. 5, p. 411-420, fev. 2018. DOI <http://dx.doi.org/10.1080/2150704x.2018.1430393>.
- WHITTAKER, Robert H.; LIKENS, Gene E. The Biosphere and Man. **Ecological Studies**, [s.l.], p.305-328, 1975. Springer Berlin Heidelberg. http://dx.doi.org/10.1007/978-3-642-80913-2_15
- WULDER, M. A.; COOPS, N. C.; ROY, D. P.; WHITE, J. C.; HERMOSILLA, T. Land cover 2.0. **International Journal of Remote Sensing**, [S. l.], v. 39, n. 12, p. 4254-4284, 2018.
- WARDLOW, B.D.; EGBERT, S.L.; KASTENS, J.H. Analysis of time-series Modis 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, v.108, p.290-310, 2007. DOI: 10.1016/j.rse.2006.11.021.
- XIA, N.; CHENG, L.; LI, M. C. Mapping urban areas using a combination of remote sensing and geolocation data. **Remote Sensing**, [S. l.], v. 11, n. 12, 2019.
- XIA, Q.; QIN, C. Z.; LI, H.; HUANG, C.; SU, F. Z. Mapping mangrove forests based on multi-tidal high-resolution satellite imagery. **Remote Sensing**, [S. l.], v. 10, n. 9, 2018.
- XIA, S.; XIONG, Z.; LUO, Y.; DONG, L.; ZHANG, G. Location difference of multiple distances based k-nearest neighbors algorithm. **Knowledge-Based Systems**, [S. l.], v. 90, p. 99-110, 2015.
- XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, [S. l.], v. 1, n. 1, p. 9-23, 2008.
- YONG, Ye *et al.* Processes of organic carbon in mangrove ecosystems. **Acta Ecologica Sinica**, [S. l.], v. 31, n. 3, p. 169-173, jun. 2011. DOI <http://dx.doi.org/10.1016/j.chnaes.2011.03.008>.
- ZAHED, N.; NAJIB, M. S.; TAJUDDIN, S. N. Categorization of Gelam, Acacia and Tualang Honey Odor-Profile Using K-Nearest Neighbors. **International Journal of Software Engineering and Computer Systems**, [S. l.], v. 4, n. 1, p. 15-28, 2018.

ZHAO, Chuanpeng; QIN, Cheng-Zhi. 10-m-resolution mangrove maps of China derived from multi-source and multi-temporal satellite observations. **Isprs Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 169, p. 389-405, nov. 2020. DOI <http://dx.doi.org/10.1016/j.isprsjprs.2020.10.001>.