



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

GUILHERME OLIVEIRA DA ROCHA CUNHA

**AVALIAÇÃO DO POTENCIAL DE IMAGENS DE RADAR DO TIPO *GROUND
RANGE DETECTED* PARA O MAPEAMENTO DO USO E COBERTURA DA
TERRA NA REGIÃO COSTEIRA DE JABOATÃO DOS GUARARAPES - PE**

Recife

2021

GUILHERME OLIVEIRA DA ROCHA CUNHA

AVALIAÇÃO DO POTENCIAL DE IMAGENS DE RADAR DO TIPO *GROUND RANGE DETECTED* PARA O MAPEAMENTO DO USO E COBERTURA DA TERRA NA REGIÃO COSTEIRA DE JABOATÃO DOS GUARARAPES - PE

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Bacharel em Engenharia Cartográfica e de Agrimensura.

Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.

Recife

2021

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

C972a Cunha, Guilherme Oliveira da Rocha.
Avaliação do potencial de imagens de radar do tipo Ground Range Detected para o mapeamento do uso e cobertura da terra na Região Costeira de Jaboatão dos Guararapes – PE / Guilherme Oliveira da Rocha Cunha. – 2021.
78 f.: il., figs., tabs.

Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.
TCC (Graduação) – Universidade Federal de Pernambuco. CTG. Departamento de Engenharia Cartográfica e de Agrimensura, 2021.
Inclui referências.

1. Engenharia cartográfica. 2. Sentinel-1A. 3. Áreas costeiras. 4. Ground Range Detected. 5. Random Forest. 6. Classificação supervisionada. I. Candeias, Ana Lúcia Bezerra (Orientadora). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2022-238

GUILHERME OLIVEIRA DA ROCHA CUNHA

AVALIAÇÃO DO POTENCIAL DE IMAGENS DE RADAR DO TIPO *GROUND RANGE DETECTED* PARA O MAPEAMENTO DO USO E COBERTURA DA TERRA NA REGIÃO COSTEIRA DE JABOATÃO DOS GUARARAPES - PE

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

Aprovado em: 14/12/2021.

BANCA EXAMINADORA

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

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

Prof. Dr. Marcelo Antônio Nero (Examinador Externo)
Universidade Federal de Minas Gerais

AGRADECIMENTOS

Agradeço aos meus pais, Geralda Oliveira e Alessandro Cunha, por terem sido responsáveis pela construção dos meus princípios e valores e por me apoiarem em diferentes momentos da minha vida, e também à minha avó Valdinete Cunha pelos cuidados e compreensão.

Agradeço aos amigos pelo apoio, amigos estes que a UFPE me proporcionou e também aos amigos de fora da universidade que fiz ao longo destes últimos anos, principalmente ao meu melhor amigo Izair Júnior.

Agradeço à minha orientadora Ana Lúcia pela dedicação e pela motivação não apenas para a produção deste trabalho, mas também por me apoiar e me instruir desde o início do curso, se tornando uma amiga.

Agradeço a todos os professores do Departamento de Engenharia Cartográfica e de Agrimensura, e também de outros departamentos, por auxiliarem na minha formação acadêmica e profissional.

Agradeço à Agência Espacial Europeia (*European Space Agency* – ESA) pelo acesso gratuito às imagens multiespectrais orbitais de radar e óticas utilizadas e também à Agência Pernambucana de Águas e Clima (APAC) pela concessão do material de apoio utilizado neste trabalho.

RESUMO

O objetivo principal deste trabalho é avaliar o potencial das imagens de radar de abertura sintética (*Synthetic Aperture Radar* – SAR) do satélite Sentinel-1A, no modo de aquisição *Interferometric Wide swath* (IW) e tipo do produto *Ground Range Detected* (GRD), para o mapeamento do uso e cobertura, obtido através de uma classificação supervisionada, de uma área localizada em uma região costeira de Jaboatão dos Guararapes, município do estado de Pernambuco. Para isto foram definidas classes temáticas que incluíssem os diferentes alvos presentes na região de estudo e escolhidas amostras de treinamento destas classes a partir de imagens óticas do satélite Sentinel-2A. Para a realização da classificação supervisionada foi utilizado o *Random Forest*, um algoritmo classificador não-paramétrico de aprendizagem de máquina (*machine learning*). Também foi realizada a classificação supervisionada através do mesmo algoritmo para as imagens óticas com o intuito de realizar a comparação da qualidade com métodos tradicionais de classificação. Os resultados foram expressos como mapas, matrizes e índices que permitiram avaliar o desempenho das classificações usando as distintas fontes de dados, apresentando resultados satisfatórios de acordo com o objetivo deste trabalho. Concluiu-se que apesar de demonstrar um desempenho menor que as imagens óticas, as imagens de radar podem ser usadas com objetivo de mapeamento de uma área costeira, e seu desempenho classificatório pode ser ampliado através de estudos aprofundados sobre a interação dos pulsos de radar com os diferentes objetos presentes na superfície terrestre.

Palavras-chave: Sentinel-1A; Áreas costeiras; Ground Range Detected; Random Forest; Classificação supervisionada.

ABSTRACT

The main objective of this work is to evaluate the potential of Synthetic Aperture Radar (SAR) images from Sentinel-1A satellite, in Interferometric Wide swath (IW) acquisition mode and Ground Range Detected (GRD) product type, for mapping the use and coverage, obtained through a supervised classification, of an area located in a coastal region of Jaboatão dos Guararapes, a municipality in the state of Pernambuco. For this purpose, thematic classes were defined that included the different targets present in the study region and training samples of these classes were chosen from optical images of the Sentinel-2A satellite. To carry out the supervised classification, Random Forest, a non-parametric machine learning classification algorithm, was used. Supervised classification was also performed using the same algorithm for optical images in order to compare the quality with traditional classification methods. The results were expressed as maps, matrices and indexes that allowed evaluating the performance of classifications using different data sources, presenting satisfactory results in accordance with the objective of this work. It was concluded that despite showing a lower performance than optical images, radar images can be used for the purpose of mapping a coastal area, and their classification performance can be expanded through in-depth studies on the interaction of radar pulses with the different objects present on the Earth's surface.

Keywords: Sentinel-1A; Coastal areas; Ground Range Detected; Random Forest; Supervised classification.

SUMÁRIO

1	INTRODUÇÃO	9
2	FUNDAMENTAÇÃO TEÓRICA	11
2.1	SENSORIAMENTO REMOTO E A RADIAÇÃO ELETROMAGNÉTICA ...	11
2.2	SENSORES ÓTICOS	14
2.2.1	Conceito.....	14
2.2.2	Calibração Radiométrica dos Dados Óticos	15
2.2.3	Correção Atmosférica	15
2.2.4	Índices por Diferença Normalizada.....	16
2.2.5	Realce de Imagens	18
2.3	SENSORES DE RADAR.....	18
2.3.1	Conceito.....	18
2.3.2	Coeficiente de Retroespalhamento	19
2.3.3	Conceito de Radar de Abertura Sintética	20
2.3.4	Parâmetros de um sistema sensor de Radar de Abertura Sintética	21
2.3.4.1	Comprimento de Onda	21
2.3.4.2	Polarização	22
2.3.4.3	Ângulo de Incidência	24
2.3.4.4	Direção de Visada	25
2.3.4.5	Resolução	26
2.3.4.6	Rugosidade Superficial	27
2.3.4.7	Constante Dielétrica e Teor de Umidade	28
2.3.4.8	Relevo e Orientação das Feições.....	28
2.3.5	Calibração Radiométrica dos Dados de Radar	29
2.3.6	Ruído <i>Speckle</i> e Filtro Espacial.....	30
2.3.7	Distorções Geométricas e Correções de Terreno	30
2.3.8	Missão Sentinel-1.....	31
2.3.8.1	Características Principais	31
2.3.8.2	Modos de Aquisição	32
2.3.8.3	Níveis de Processamento e Tipos de Produto	33
2.3.8.4	Resoluções do Sentinel-1	34
2.3.9	Missão Sentinel-2.....	34
2.3.9.1	Características Principais	34

2.3.9.2	Níveis de Processamento e Tipos De Produto	35
2.3.9.3	Resoluções do Sentinel-2	36
2.4	CLASSIFICAÇÃO SUPERVISIONADA	36
2.4.1	Classificador <i>Random Forest</i>	37
2.4.2	Validação do Desempenho Classificatório	39
3	MATERIAIS E MÉTODOS	42
3.1	ÁREA DE ESTUDO	43
3.2	DADOS E <i>SOFTWARES</i> UTILIZADOS.....	45
3.2.1	Material de Apoio Auxiliar	47
3.3	PROCESSAMENTO DAS IMAGENS	47
3.3.1	Imagens do sensor ótico	47
3.3.2	Imagens do sensor de radar	48
3.4	CLASSIFICAÇÃO SUPERVISIONADA	49
3.4.1	Definição das Classes Temáticas do Mapeamento e Amostras de Treinamento	49
3.4.2	Execução da Classificação Supervisionada	52
3.4.3	Pós-Classificação	54
3.4.4	Análise Estatística e Validação da Classificação	54
4	RESULTADOS E DISCUSSÃO	57
4.1	ANÁLISES DAS POLARIZAÇÕES VH E VV.....	57
4.2	ANÁLISE DA COMPOSIÇÃO DAS BANDAS DE RADAR E DO MATERIAL DE APOIO.....	59
4.3	MAPAS DAS CLASSIFICAÇÕES	61
4.4	TABELAS ESTATÍSTICAS	62
4.4.1	Validação dos dados de treinamento	62
4.4.2	Avaliação do desempenho das classificações	63
4.5	ANÁLISE VISUAL	66
5	CONCLUSÕES E RECOMENDAÇÕES	69
	REFERÊNCIAS	72

1 INTRODUÇÃO

No contexto de monitoramento ambiental, gestão territorial, planejamento e gerenciamento dos recursos naturais, bem como na tomada de decisões em políticas públicas, o mapeamento do uso e cobertura da terra se mostra um instrumento de relevante importância pois exerce a ligação do meio físico com o meio socioeconômico (CALIXTO *et al.*, 2017; MONTEIRO, 2008).

A utilização do Sensoriamento Remoto orbital como ferramenta para realizar este tipo de mapeamento cresceu substancialmente nos últimos anos, pelo motivo das imagens adquiridas por satélites conseguirem mapear grandes áreas da superfície com uma certa periodicidade apresentando qualidade, a um custo operacional baixo (SILVA *et al.*, 2021).

No mapeamento podem ser utilizados diversos sensores de satélites que operam em diferentes faixas do espectro eletromagnético (visível, infravermelho e micro-ondas). No que diz respeito aos sensores óticos, que operam nas faixas do visível e infravermelho, é inevitável a existência de nuvens, e da projeção de suas sombras no terreno, nas imagens deste tipo de sensor. A presença dessas nuvens e sombras causa o bloqueamento da visualização dos objetos presentes no terreno e interfere na análise quantitativa da imagem, impossibilitando a interpretação do produto e comprometendo o mapeamento (SILVA; LIPORACE, 2016; TEIXEIRA, 2011).

Em zonas costeiras com predominância de climas tropicais esse problema se agrava pois, devido à alta taxa de precipitação, é observada a presença de uma grande quantidade de nuvens em longos períodos de tempo (NOBREGA; FARIAS, 2016).

Para solucionar este problema podem ser utilizados dados de radares de abertura sintética (*Synthetic Aperture Radar* – SAR) que são satélites imageadores de radar, pois este tipo de satélite utiliza sensores ativos na faixa espectral das micro-ondas e são pouco influenciados pela cobertura de nuvens, pelos demais constituintes atmosféricos e quase todos os climas (ASNER, 2001; DINIZ, 2019; ENGELBRECHT *et al.*, 2017; HENDERSON; LEWIS, 1998; JENSEN, 2009; WOODHOUSE, 2006).

Neste trabalho foram utilizados os dados do radar de abertura sintética Sentinel-1 do tipo GRD (*Ground Range Detected*), disponibilizados gratuitamente pela Agência Espacial Europeia (*European Space Agency* – ESA), para o mapeamento da região costeira do município de Jaboatão dos Guararapes – PE. Essa região apresenta um clima tropical quente e úmido.

O sensor SAR/Sentinel-1 utiliza a Banda C que atua com uma amplitude de comprimento de onda de 3,8 a 7,5 cm, apresentando alta confiabilidade e cobertura geográfica (ESA, 2021).

Para o entendimento do funcionamento dos sensores SAR e para auxiliar na interpretação das imagens, foram abordados os parâmetros que interferem no valor do retroespalhamento, ou seja, o pulso de micro-ondas que retorna ao sensor. Este tipo de conhecimento é necessário pois ajuda a entender como ocorre a interação da energia eletromagnética com os alvos. De acordo com Lewis e Henderson (1998), os parâmetros principais que influenciam no valor da energia retroespalhada estão relacionados ao sistema sensor e ao alvo.

Usualmente são utilizadas imagens de sensores óticos para realizar o mapeamento de uso e cobertura da terra, no entanto, a utilização de imagens de sensores de radar está sendo ampliada nos últimos anos (TEIXEIRA, 2011). Apesar de existirem muitos estudos empregando dados de SAR/Sentinel-1 para o mapeamento, poucos têm utilizado imagens do tipo GRD. O objetivo deste trabalho foi avaliar se este tipo de produto é útil para este tipo de mapeamento.

Como método avaliativo foi realizada uma classificação supervisionada utilizando um algoritmo classificador não-paramétrico para as imagens de radar do Sentinel-1 e para as imagens óticas do Sentinel-2, também disponibilizadas pela ESA. Desta forma foi possível avaliar o desempenho classificatório utilizando imagens de radar do tipo GRD e também comparar com uma classificação supervisionada feita com dados óticos.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão expostas as informações fundamentais necessárias para a compreensão da metodologia utilizada no trabalho.


2.1 SENSORIAMENTO REMOTO E A RADIAÇÃO ELETROMAGNÉTICA

O Sensoriamento Remoto corresponde à ciência composta por técnicas e métodos que se encarregam de obter informações sobre fenômenos, áreas ou objetos mediante a uma análise conjunta de dados captados por instrumentos à distância, isto é, sem que haja contato físico com o objeto, área ou fenômeno que está sendo estudado. (KIEFER, 1994; LANDGREBE, 1978; LILLESAND; NOVO, 1995; ROUGHGARDEN *et al.*, 1991). De forma mais específica, Meneses e Almeida (2012) relatam que o Sensoriamento Remoto tem por objetivo a elaboração de imagens da superfície terrestre através da detecção, mensuração quantitativa e interpretação das interações entre a radiação eletromagnética e os objetos presentes na superfície terrestre. Algumas aplicações desta ciência são usualmente conhecidas ou utilizadas, dentre elas destacam-se o monitoramento ambiental, a detecção e o monitoramento constante de mudanças no cenário global, o acompanhamento da agricultura, a supervisão da exploração de recursos naturais, a elaboração de produtos cartográficos, a meteorologia, estudos de uso e cobertura da terra, e reconhecimentos e vigilâncias militares diversos (CATALÃO, 2013).

Os sensores remotos orbitais detectam e medem a radiação eletromagnética (REM). A REM é a maneira pela qual ocorre a transmissão de energia por meio de um campo eletromagnético variante, no qual os campos elétricos e magnéticos configuram direções de forma perpendiculares entre si. É por intermédio desta forma de transmissão que a energia gerada pelo Sol alcança a Terra (QUARTAROLI; VICENTE; ARAÚJO, 2014).

A radiação eletromagnética dispõe de três características importantes: o comprimento de onda, a frequência e a amplitude. O comprimento de onda refere-se à distância entre duas cristas de onda sucessivas, isto é, a lonjura da crista de uma onda à crista da onda seguinte, podendo ser medida em nanômetros, micrômetros ou centímetros. A frequência corresponde ao número de cristas ou de ciclos da onda, passando por um ponto fixo em um determinado intervalo de tempo, sendo medida em hertz. A amplitude é a altura de cada pico (SARAIVA, 2015). À vista disto, os aspectos caracterizantes da energia eletromagnética podem ser observados utilizando tanto a frequência como o comprimento de onda, sendo o comprimento de onda a convenção comum para definir regiões do espectro eletromagnético no campo do Sensoriamento Remoto (CAMPBELL, 1996).

Figura 1 – Representação da propagação da REM na forma de onda em função das oscilações perpendiculares dos campos elétrico e magnético.



Fonte: Meneses e Almeida (2012).

O espectro eletromagnético é a forma pela qual a radiação eletromagnética (REM) está disposta, na configuração de um ordenamento contínuo, conforme o seu comprimento de onda ou sua frequência. Ainda que o espectro eletromagnético seja contínuo, sua divisão é feita de forma arbitrária pelo ser humano em intervalos de comprimento de onda baseados nos mecanismos físicos que geram energia eletromagnética e os mecanismos físicos de sua detecção, intervalos esses denominados como faixas ou bandas espectrais (QUARTAROLI; VICENTE; ARAÚJO, 2014). A detecção da energia emitida ou refletida ocorre em faixas ou bandas nas quais o sensor remoto atua (ANTUNES, 2002).

De acordo com Meneses e Almeida (2012), para o Sensoriamento Remoto são estabelecidas definições fundamentais para a assimilação do conteúdo dos componentes de um modelo simples desta ciência, dentre estas destacam-se:

- Energia radiante: refere-se à energia propagada da fonte no formato de ondas eletromagnéticas;
- Fluxo radiante: refere-se à taxa na qual a energia radiante é transportada de um ponto ou superfície para outra superfície;
- Irradiância: refere-se ao fluxo radiante solar que incide na superfície do terreno por área de superfície;
- Radiância: refere-se à medida realizada pelo sensor da densidade de fluxo radiante que deixa um elemento de área da superfície do terreno, e que é propagado em uma direção delimitada por um cone elementar de um ângulo sólido contendo aquela direção; e
- Reflectância: refere-se à razão entre a quantidade de energia radiante que deixa uma unidade de área no terreno (Radiância) pela quantidade de energia que incide na mesma área (Irradiância), medida no mesmo instante de tempo.

Um termo importante do estudo do Sensoriamento Remoto é denominado assinatura espectral. Ela pode ser definida como o comportamento espectral que um material exhibe quando interage com a radiação eletromagnética em um determinado comprimento de onda. (MENESES; ALMEIDA, 2012).

2.2 SENSORES ÓTICOS

Nesta seção serão apresentados os conceitos básicos relativos aos sensores óticos.

2.2.1 Conceito

Os sensores óticos fazem uso das regiões do visível, infravermelho próximo e infravermelho de ondas curtas para elaborarem imagens da superfície terrestre por meio da detecção de radiação eletromagnética solar refletidas pelos alvos na superfície (SARAIVA, 2015). Os sensores óticos são conceituados como sistemas passivos, visto que não dispõem de fonte própria de radiação (FONSECA; FERNANDES, 2004). Os tipos de sistemas principais podem ser categorizados como multiespectrais e hiperespectrais (SARAIVA, 2015).

Sensores imageadores multiespectrais na faixa ótica podem ser definidos como instrumentos eletro-ópticos capazes de capturar de forma simultânea imagens múltiplas da superfície da Terra, desde o comprimento de onda da luz visível azul, até a região termal. Neste caso o sensor conta com multicanais que abarcam algumas bandas espectrais. Cada canal é susceptível à radiação de uma banda definida ou faixa de comprimento de onda, resultando na formação de uma imagem de multicamadas espectrais. (MENESES; ALMEIDA, 2012; SARAIVA, 2015).

2.2.2 Calibração Radiométrica dos Dados Óticos

Por meio da calibração radiométrica há como ser feita a comparação entre imagens obtidas em datas distintas ou oriundas de sensores diferentes. Este procedimento viabiliza que os números digitais da imagem se convertam em variadas quantidades que possibilita esta comparação, como é o caso da reflectância espectral (CHANDER *et al.*, 2009).

Ao se comparar imagens que provêm de sensores distintos, encontram-se três vantagens em usar a reflectância ao nível do topo da atmosfera. Primeiramente, esta retira o efeito do cosseno dos diferentes ângulos zenitais solares em virtude dos horários alternados na aquisição das imagens. Em segundo lugar, a reflectância espectral permite a compensação dos diferentes valores de irradiância solar exoatmosférica provenientes das diversas bandas espectrais. Por último, a reflectância também corrige a variação da distância Terra-Sol através dos momentos distintos de aquisição. Através das imagens de reflectância podem ser realizadas as correções atmosféricas e o cálculo de índices por diferença normalizada (CHANDER *et al.*, 2009; SARAIVA, 2015).

2.2.3 Correção Atmosférica

A atmosfera é a fonte de erro de degradações ou distorção radiométricas que alteram radiometricamente a imagem por completo, cuja a intensidade dos efeitos é dependente do comprimento de onda, da data de imageamento e da trajetória da radiação. Ela interfere na radiação medida em qualquer ponto da imagem a partir de duas formas: primeiro, ela age tal qual um refletor ao adicionar uma radiação extra ao sinal captado pelo sensor; segundo, ela também atua como um absorvedor, capaz de amenizar a intensidade de energia que está a iluminar o alvo na superfície (MENESES; ALMEIDA, 2012).

As correções atmosféricas removem o efeito da dispersão molecular e absorção por gases, como exemplo do vapor de água, oxigênio, ozônio e aerossóis, partindo de duas etapas fundamentais: estimativa de parâmetros e recuperação da refletância da superfície (LIANG *et al.*, 2001; RICHTER, 1996). Em virtude da interferência do espalhamento atmosférico, o procedimento de correção atmosférica também tem importante destaque para o cálculo de índices de vegetação que são apurados a partir de duas ou mais bandas espectrais (FREIRES *et al.*, 2020; MATHER, 1999). Em suma, para que se atenuem os impactos da influência atmosférica sobre os valores de níveis de cinza registrados em uma dada cena é preciso que se realize a correção atmosférica (NOVO, 1995).

As imagens que são adquiridas a partir dos satélites óticos são disponibilizadas com valores de reflectância aparente, também denominada como reflectância do topo da atmosfera (*Top Of Atmosphere* – TOA). Após a operação da correção atmosférica, são gerados valores de reflectância de superfície da imagem (*Bottom Of Atmosphere* – BOA) (REZENDE; MARQUES; ROSA, 2017).

2.2.4 Índices por Diferença Normalizada

Quando ocorre o procedimento de extração de informações das imagens geradas por sensores multiespectrais, é provável que haja a intenção de se discriminar pontos específicos, quer seja um tipo de solo, uma vegetação, áreas edificadas, entre outros. Para tanto é necessário certificar-se de métodos que garantam o enfoque exclusivo nas propriedades intrínsecas àquele alvo específico, para que outros objetos não se sobressaiam, isto é, destaque exclusivo de um tipo de alvo. A operação aritmética utilizada para atingir este fim é a divisão ou razão de bandas, visto que em seus fundamentos estão os parâmetros dos aspectos físicos do sensor e o comportamento da reflectância dos alvos e suas respectivas assinaturas espectrais (MENESES; ALMEIDA, 2012). Os Índices por Diferença Normalizada tratam-se de índices físicos gerados a partir da razão entre bandas espectrais específicas.

O Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) varia de -1 a 1, se trata de um índice obtido a partir de dados espectrais para explicitar as áreas com cobertura vegetal e as condições vegetativas, isto é, o vigor da vegetação, representado numericamente por cada pixel da imagem, a partir da razão entre bandas de reflectância na faixa espectral do vermelho e do infravermelho próximo (ALBUQUERQUE *et al.*, 2015).

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

O Índice de Água por Diferença Normalizada (*Normalized Difference Water Index* – NDWI) varia de -1 a 1, foi desenvolvido para maximizar a reflectância típica da água, logo realça vários tipos de corpos hídricos. Para isto é efetuada a razão entre bandas de reflectância na faixa espectral do verde e do infravermelho próximo (FERREIRA *et al.*, 2013).

$$NDWI = \frac{(\rho_{GRE} - \rho_{NIR})}{(\rho_{GRE} + \rho_{NIR})} \quad \text{Equação 2}$$

O Índice de Construção por Diferença Normalizada (*Normalized Difference Built-Up Index*) varia de -1 a 1, foi criado para identificar áreas urbanas e construídas a partir da razão entre bandas de reflectância na faixa espectral do infravermelho próximo e infravermelho médio (PINHEIRO; LARANJEIRA, 2013).

$$NDBI = \frac{(\rho_{SWIR} - \rho_{NIR})}{(\rho_{SWIR} + \rho_{NIR})} \quad \text{Equação 3}$$

Onde ρ_{NIR} é a reflectância no infravermelho próximo; ρ_{RED} é a reflectância no vermelho; ρ_{GRE} é a reflectância no verde; e ρ_{SWIR} é a reflectância no infravermelho médio.

Para ser executada a razão entre bandas, o valor do número digital (*Digital Number* – DN) de uma banda espectral é dividido pelo valor correspondente do número digital em outra banda. A razão entre bandas de imagens multiespectrais resulta no destaque das sutis diferenças de cor ou de reflectância espectral entre objetos da superfície que em imagens padrão dificilmente são detectadas (AVERY; BERLIN, 1992). Esta operação pode remover os efeitos de ganho que são provocados por variações espaciais ou temporais que ocorrem em bandas de uma mesma imagem, além de ser bastante utilizada na determinação dos índices de biomassa ou de vegetação (CRÓSTA, 1993; SPRING, 1998).

2.2.5 Realce de Imagens

Com o propósito de tornar a interpretação visual de uma imagem digital mais fácil, o realce de imagens aparece como um recurso fundamental que torna ainda mais sofisticada a detectabilidade dos objetos, alvos ou parâmetros em questão (AVERY; BERLIN, 1992).

De acordo com Lillesand e Kiefer (1994) os métodos e técnicas utilizados no realce de imagem podem ser divididos em três categorizações: manipulação do contraste, manipulação das características espaciais e manipulação de multi-imagem.

2.3 SENSORES DE RADAR

Nesta seção serão apresentados os conceitos básicos relativos aos sensores de radar.

2.3.1 Conceito


O Radar (acrônimo de *Radio Detection and Ranging*) corresponde a uma espécie de dispositivo sensor habilitado para captar dados informativos dos alvos por meio da indicação de sua posição e distância (SABINS, 1997). O sistema radar imageador é considerado um sistema ativo, visto que este possui sua fonte própria de energia para a obtenção de uma imagem, podendo desta forma operar tanto durante o dia quanto à noite (TEIXEIRA, 2011). Devido ao trabalho desempenhado através das micro-ondas, eles atuam praticamente sem a interferência das nuvens, neblinas ou precipitações, o que torna possível uma cobertura dos objetos mesmo em circunstâncias adversas de tempo (AYTEKIN *et al.*, 2013; FENG *et al.*, 2011; HENDERSON; LEWIS, 2008; JENSEN, 2009; NOVO, 2009, 2010; PONZONI *et al.*, 2015; SERVELLO *et al.*, 2015; WOODHOUSE, 2006).

A operação de um sistema radar constitui-se da transmissão de um sinal eletromagnético de micro-ondas direcionado ao alvo por meio de uma antena e da detecção da porção reenviada do sinal. Ao ser reenviado, o sinal tem sua intensidade medida para que seja possível diferenciar os distintos objetos e o intervalo de tempo entre os sinais transmitido e refletido possibilitam mensurar a distância ao objeto ou o alcance (“*range*”) (FONSECA; FERNANDES, 2004). A fração da energia que é espalhada em direção ao próprio sensor é intitulada como retroespalhamento (*backscattering*) e é recuperada conforme o deslocamento do sensor.

Um importante parâmetro definido pelo valor do retroespalhamento em relação à quantidade de energia que foi emitida pelo sensor (pulso de micro-ondas) é denominado como coeficiente de retroespalhamento ou sigma zero (σ^0) (RANEY, 1998, ROSOT, 2001). O retroespalhamento está ligado principalmente à rugosidade da superfície terrestre. A potência que é recebida pela antena de radar refere-se tanto às características do sistema de radar, quanto do objeto imageado e do sinal espalhado pelo objeto (LEWIS; HENDERSON, 1998; TEIXEIRA, 2011).

Os radares se apresentam sensíveis às propriedades do solo (umidade e rugosidade) e da vegetação (estrutura e biomassa), como resultado eles proporcionam informação extra dos tipos de cobertura, uso e cobertura da terra, no que se refere às informações obtidas pelas imagens óticas (JIN *et al.*, 2014).

Figura 3 – Modelo de propagação de pulsos de onda por um radar de visada lateral e o retorno dos pulsos para a antena, após serem retroespalhados pelos alvos.



Fonte: Meneses e Almeida (2012).

2.3.2 Coeficiente de Retroespalhamento

O coeficiente de retroespalhamento (σ^0), também conhecido como coeficiente de retrodispersão, é representado pela seção cruzada do sinal de radar por unidade de área no alcance do terreno e corresponde a energia que retorna ao sensor. Ademais, este coeficiente também se configura como a razão da densidade de potência espalhada média pela superfície numa esfera de raio r , sofrendo alterações conforme os padrões do sensor e dos alvos em questão. (HENDERSON; LEWIS, 1998; LEE; POTTIER, 2009).

Elucidando de forma prática, o coeficiente de retroespalhamento pode ser compreendido como uma mensuração quantitativa da intensidade de energia que retorna à antena do radar (SABINS, 1997). A medida deste coeficiente é geralmente dada em decibéis (dB), por conta da sua grande variação para diversos alvos e objetos (NOVO, 2010; WARING *et al.*, 1995).

2.3.3 Conceito de Radar de Abertura Sintética

Dentre as tecnologias dos sistemas radar, existe um segmento de implementação específico denominado Radar de Abertura Sintética (*Synthetic Aperture Radar – SAR*), que em seu funcionamento é feito o uso do movimento da plataforma e do processamento especializado de sinal para que sejam produzidas imagens com alta resolução (ZYL; KIM, 2011). Análogo ao que acontece no processamento convencional dos sistemas radar, as ondas eletromagnéticas são transmitidas de forma sequencial e os ecos retrodispersados são detectados pela antena. No contexto do sistema SAR, o tempo consecutivo da transmissão e recepção traduz-se em posições distintas em virtude do movimento da plataforma. Ao serem recebidos, o arranjo coerente dos sinais oportuniza o surgimento de uma abertura sintética mais longa que o comprimento da antena física (MOREIRA *et al.*, 2013).

Devido ao comprimento da antena, os radares de abertura real sofrem com a limitação da sua resolução azimutal. Com o objetivo de contornar esta situação, foi elaborado o radar de abertura sintética, que constrói de forma artificial uma antena longa e virtual, a “antena de abertura sintética” que faz uso do efeito de posições consecutivas da antena tratadas eletronicamente como se fossem componentes de uma única antena longa (RANEY, 1998). Os radares de abertura sintética operam em uma geometria de visada lateral, onde a direção de iluminação é perpendicular à linha de órbita. Desta forma, define-se a direção de órbita como direção de azimute e o eixo ortogonal à direção de azimute como direção de alcance ou range (LEE; POTTIER, 2009; RANEY, 1998).

As imagens SAR são utilizadas para diversos estudos: mapeamento de uso e cobertura da terra, monitoramento da cobertura de neve, movimentos de massa, avalanches, detecção de embarcações marítimas, elaboração de modelos digitais de superfície, entre outros. Devido à sua característica de sofrerem pouca influência das condições atmosféricas, podem ser uma alternativa para a detecção de desflorestamentos em regiões tropicais e estudos em áreas litorâneas (FERREIRA, 2018; HENDERSON; LEWIS, 1998).

2.3.4 Parâmetros de um sistema sensor de Radar de Abertura Sintética

A interpretação das imagens de radar e a discriminação dos diversos alvos passíveis de análise são possíveis quando se há um conhecimento efetivo da interação entre a energia incidente e a superfície imageada. A compreensão desta relação tem como fundamento primordial o retroespalhamento, ou seja, a intensidade do retorno dos sinais de radar, no qual esta intensidade depende dos parâmetros do sistema sensor de radar (comprimento de onda, polarização, ângulo de incidência, direção de visada e resolução), bem como dos parâmetros inerentes ao alvo (rugosidade superficial, constante dielétrica e teor de umidade e relevo e orientação das feições) (AVERY; BERLIN, 1992; LEWIS; HENDERSON, 1998).

A composição das imagens de radar se dá a partir de muitos componentes de brilho variado, e estas variações correspondem, ainda que parcialmente, às mudanças de lugar para lugar que ocorrem de forma interna na própria paisagem. Compreender estas correspondências é o princípio essencial para guiar inferências acerca das propriedades de uma paisagem. Todavia, ao executar uma interpretação coerente e rigorosa de uma imagem de radar são encontradas algumas dificuldades que dentre elas destaca-se o fato de que os sinais que retornam da superfície do terreno dispõem de grande amplitude de variação, resultando desde imagens claras (altos níveis de brilho), até imagens escuras (baixos níveis de brilho) (ROSOT, 2001).

2.3.4.1 Comprimento de Onda

O comprimento de onda e a frequência são grandezas que possuem uma relação, apresentada na Equação 4 abaixo (LEWIS; HENDERSON, 1998):

$$\lambda = \frac{c}{f} \quad \text{Equação 4}$$

Nesta equação λ refere-se ao comprimento de onda, c refere-se à velocidade da luz e f refere-se à frequência (Hz).

As informações obtidas dos alvos estão relacionadas com às regiões espectrais utilizadas. No contexto do sensoriamento remoto ativo, os comprimentos de onda mais usados são muito maiores que os comprimentos de onda relacionados às faixas espectrais do visível, do infravermelho próximo ou do infravermelho termal, como pode ser visto na Tabela 2 (DINIZ, 2019).

Tabela 2 – Denominação de bandas, comprimentos de onda e frequências de radar.

Banda	Amplitude de comprimentos de onda (cm)	Frequência (GHz)
K _a	0,8 – 1,1	40,0 – 26,5
K	1,1 – 1,7	26,5 – 18,0
K _u	1,7 – 2,4	18,0 – 12,5
X	2,4 – 3,8	12,5 – 8,0
C	3,8 – 7,5	8,0 – 4,0
S	7,5 – 15,0	4,0 – 2,0
L	15,0 – 30,0	2,0 – 1,0
P	30,0 – 100,0	1,0 – 0,3

Fonte: Rosot (2001).

De modo habitual, as bandas que são usadas pelos radares imageadores consistem nas bandas X, C, S, L e P. O comprimento de onda representa uma variável relevante pois controla o coeficiente de retroespalhamento e a profundidade de penetração do sinal de micro-ondas. Para comprimentos de onda maiores, aumenta-se a capacidade de penetração através da precipitação e em uma camada de superfície. Os radares que atuam em comprimento de onda maior que 2 cm não são afetados substancialmente pela cobertura de nuvens. No entanto, a chuva aparece como um ponto de extrema importância nos comprimentos de onda inferiores a 4 cm (PARADELLA, 1996; TEIXEIRA, 2011).

2.3.4.2 Polarização


O fenômeno da polarização trata da orientação do plano do vetor campo elétrico de uma onda, quando observado na direção de propagação. Devido à natureza ativa dos sistemas imageadores de radar, estes comumente tanto emitem quanto recebem ondas que são linearmente polarizadas, isto significa que dão origem às ondas eletromagnéticas com um campo elétrico em plano fixo na direção de propagação.

Considerando um comprimento de onda fixo, a profundidade da radiação que penetra sofre influência do fenômeno da polarização. São permitidas pelos sistemas de radar quatro possíveis combinações de polarização que atuam de modo a possuir uma relação direta na interação da radiação de micro-ondas para com os objetos que estão na superfície (FERREIRA, 2018; PONZONI *et al.*, 2015; ROSOT, 2001; ULABY, 1986; WOODHOUSE, 2006):

- HH onde o pulso é transmitido e recebido horizontalmente;
- VV onde o pulso é transmitido e recebido verticalmente;
- VH onde o pulso é transmitido verticalmente e recebido horizontalmente;
- HV onde o pulso é transmitido horizontalmente e recebido verticalmente.

Por ser um fator de destaque no que tange ao retorno dos sinais, a polarização pode desenvolver uma função colaborativa nos procedimentos de identificação de alvos diversos ao longo da superfície terrestre. Isto posto, em determinadas culturas utilizar-se de polarizações cruzadas (diferentes direções de emissão e retorno do sinal) pode tornar o processo de identificação e diferenciação mais fácil, ou em outros casos, fazer uso de polarizações paralelas (iguais direções de emissão e retorno do sinal) possibilitam uma profundidade de penetração maior em áreas florestais com solos secos. Apresentando extrema complexidade da interação dos sinais de radar com as feições, e também considerando a sua dependência das características da superfície como o relevo, a vegetação e cobertura vegetal, rugosidade, conteúdo de umidade do solo, pode-se dizer que não é em todo caso que se pode prever se imagens HH ou HV irão indicar maior conteúdo de informação para uma determinada aplicação (FUNG; ULABY, 1983; LILLESAND; KIEFER, 1994).

Figura 4 – Direções de propagação do campo elétrico: a - Polarização vertical e b - Polarização horizontal.




Fonte: Teixeira (2011), modificado de Van der Sanden (1997).

2.3.4.3 Ângulo de Incidência

O ângulo de incidência (θ) corresponde ao ângulo estabelecido entre a direção de iluminação do radar e a vertical do solo. Este ângulo em questão pode variar em dois alcances, a depender da altura da trajetória do radar: o alcance próximo e o alcance distante. Essa mudança de ângulo afeta a geometria de visada. O ângulo de incidência também influencia fortemente o coeficiente de retroespalhamento. Vale ressaltar que superfícies distintas podem exibir uma diferenciação de seu sinal devido ao comportamento angular do retroespalhamento (LANG *et al.*, 2008; WANG *et al.*, 1995).

O ângulo de incidência local (α) por sua vez é medido considerando o declive local do terreno partindo de qualquer ponto da imagem. Por meio deste ângulo é possível determinar de forma parcial o brilho ou a tonalidade de cada pixel, em outros termos, a declividade do local pode gerar um efeito relevante sobre o brilho da imagem (TEIXEIRA, 2011).

Figura 5 – Desenho esquemático do ângulo de incidência e ângulo de incidência local.




Fonte: Teixeira (2011).

2.3.4.4 Direção de Visada

A direção de visada ou ângulo de visada é compreendida como o ângulo em sentido horário formado entre o norte geográfico e a direção do feixe de iluminação do radar, significa ser a perpendicular à direção de movimento da plataforma (LEWIS; HENDERSON, 1998). Usualmente a direção de visada tem uma implicação considerável na interpretação das feições em uma imagem. O nível de realce ou supressão de feições lineares nas imagens depende principalmente da sua orientação relativa a uma dada direção de visada da iluminação do radar (TEIXEIRA, 2011).

As feições que se posicionam em uma direção ortogonal à direção de visada geralmente são muito mais realçadas, ocorrendo um aumento no coeficiente de retroespalhamento. De modo oposto, quando se organizam de forma paralela à iluminação as feições lineares interagem menos com a radiação incidente, resultando na diminuição do coeficiente de retroespalhamento (JENSEN, 2009; TEIXEIRA, 2011).

Figura 6 – Demonstração do ângulo de visada.



Fonte: Ferreira (2018).


2.3.4.5 Resolução

A resolução é definida como a distância mínima que descreve a capacidade do radar em distinguir alvos refletoras posicionados em pequenos intervalos. Se referindo ao sistema SAR, a resolução é medida nas direções de azimute e alcance e esta é conduzida e regulada pelos atributos do sistema radar e do sensor (RANEY, 1998; TEIXEIRA, 2011).

A resolução em alcance (“*range*”) de um radar de abertura sintética é mensurada ao longo da direção de iluminação do radar, e é proporcional ao comprimento do pulso processado. À medida que o comprimento do pulso é menor, mais detalhada e precisa será a resolução em alcance. Os dados de radar são produzidos no campo do alcance inclinado (“*slant-range*”), todavia usualmente são projetados sobre o plano do alcance no terreno (“*ground-range*”) ao serem processados numa imagem. A resolução em alcance é entendida como a projeção no solo da resolução na linha de visada ou resolução espacial em distância. A resolução em questão pode ser melhorada com a ampliação do espaço entre o sensor e o alvo (ROSOT, 2001; TEIXEIRA, 2011).

A resolução azimutal ou resolução ao longo da trajetória é definida como a largura da faixa do território que é iluminada pelo pulso do radar, que por seu turno, é adquirido em função da largura do feixe de um radar de abertura real (AVERY; BERLIN, 1992). No sistema de um SAR, a resolução azimutal não possui dependências da distância entre a antena e o alvo, altura de voo, ângulo de incidência e comprimento de onda utilizados no imageamento (ROSOT, 2001).

Figura 7 – Representação tridimensional da célula de resolução no espaço iluminado.




Fonte: Teixeira (2011).

2.3.4.6 Rugosidade Superficial

O retroespalhamento está ligado à rugosidade da superfície terrestre. Devido à interferência da rugosidade da superfície são ocasionadas alterações no retorno das micro-ondas ao sistema radar, correspondendo a um fator dominante na tonalidade da imagem. Em zonas que possuem uma superfície lisa em relação ao comprimento de onda, o espalhamento acontece em direção contrária ao sensor, ocorrendo uma reflexão especular assim resultando no retorno de pouca radiação para a antena. Já nas zonas que possuem superfícies rugosas, o processo de espalhamento ocorre em diversas direções, amplificando o espalhamento dos sinais dando origem à reflexão difusa. O surgimento de um terceiro tipo de espalhamento se dá no momento em que duas ou mais superfícies lisas estão posicionadas de forma adjacente, sendo este processo classificado como reflexão de canto (FERREIRA, 2018; FREITAS *et al.*, 2007; MENESES; SANO, 2011; PONZONI *et al.*, 2015; WOODHOUSE, 2006). A mensuração da rugosidade é feita em centímetros e a sua definição se dá a partir das características texturais, sendo estas passíveis de comparação em tamanho em relação ao comprimento de onda do radar (SABINS, 1997).

Um fenômeno conhecido é o de que objetos pequenos são capazes de se mostrar extremamente brilhantes em imagens de radar. Este fenômeno ocorre essencialmente em virtude da configuração geométrica do objeto. Na ocasião em que duas ou três superfícies se interceptam a formar ângulos retos ou quando estão direcionados ao sensor radar, se constitui como um refletor de canto (*corner reflector*), tornando mais forte o sinal de retorno (FUNG; ULABY, 1983; ROSOT, 2001).

Figura 8 – Modelo de padrões de espalhamento para uma superfície horizontal: a - Superfície lisa; b - Superfície intermediária e c - Superfície rugosa.



Fonte: Teixeira (2011).

2.3.4.7 Constante Dielétrica e Teor de Umidade

A constante dielétrica corresponde à uma medição das propriedades elétricas dos materiais, abrangendo as suas capacidades de absorção, reflexão e transmissão da radiação das micro-ondas como resposta a um sinal incidente. Quando existe a presença de umidade no material também existe a amplificação da constante dielétrica do material, interferindo na maneira pela qual este material é visto em uma imagem de radar. No momento em que as micro-ondas reconhecem a presença de água, uma parte significativa da energia se dispersa na superfície por conta da constante dielétrica de água, em volta de 80 (imagem clara). Em contrapartida, nas superfícies secas a penetração das micro-ondas é maximizada, visto que o valor da constante dielétrica é diminuído substancialmente girando em torno de 3 a 8 (imagem escura). Materiais idênticos podem sofrer variações na aparência dados momentos ou locais diferentes, a depender do teor de umidade. O retroespalhamento, e por conseguinte, o brilho da imagem, em zonas com vegetação ou superfícies naturais, é ampliado com o aumento do teor de umidade, haja posto que nos terrenos com maior teor de umidade ocorre uma diminuição da penetração das micro-ondas abaixo da superfície e através do dossel da vegetação. Quanto maior for a constante dielétrica do material, maior acaba sendo a interação do campo elétrico do pulso de micro-ondas com a molécula de água e mais intenso é o retorno do sinal, e vice-versa (LEWIS; HENDERSON, 1998; NOVO, 2009, 2010; ROSOT, 2001; TEIXEIRA, 2011).

2.3.4.8 Relevô e Orientação das Feições

O ângulo formado, em direção descendente, entre um plano horizontal até um ponto específico do feixe radar, ou seja, o ângulo formado entre a linha de horizonte de órbita e a linha que define a direção de visada corresponde ao ângulo de depressão. Ao serem medidos em posição equivalentes do feixe, os ângulos de depressão e de visada são complementares, isto é, a sua soma é igual a 90° (ROSOT, 2001).

Nas localidades que dispõem de terrenos onde os seus aclives estão direcionados para a fonte do sinal de radar (antena) são gerados retornos intensos, visto que quando o aclave é perpendicular ao feixe radar ocorre a maior quantidade de reflexão (AVERY; BERLIN, 1992). Designada como incidência normal, esta condição aponta que as trajetórias de incidência e reflexão são as mesmas e pode ser comprovada sempre que o resultado da soma do ângulo de depressão e do ângulo de aclave for igual a 90° . A ocorrência do fenômeno de incidência normal pode camuflar e mascarar todos os dados referentes ao micro-relevo do aclave ao gerar uma zona de brilho excessivo na imagem (ROSOT, 2001).

De uma maneira análoga, os declives presentes ao longo do terreno provocam tons mais escurecidos, isto é, manifestam uma quantidade menor de retorno ao serem iluminados pelo radar. A produção de sinais de retorno será aumentada à medida que o ângulo do declive for menor que o ângulo de depressão. As variações de retorno ocasionadas entre os declives e os aclives enfatizam a topografia da região na compreensão e interpretação das imagens de radar (ROSOT, 2001).

2.3.5 Calibração Radiométrica dos Dados de Radar

A calibração radiométrica converte a intensidade de retroespalhamento recebida pelo sensor para a seção transversal normalizada do radar sigma zero (σ°) como uma medida calibrada levando em consideração o ângulo de incidência global da imagem e outras características específicas do sensor. Isso torna as imagens de radar de diferentes datas, sensores ou geometrias de imagem comparáveis. A técnica da calibração radiométrica converte os números digitais dos pixels da imagem SAR em valores de retrodispersão que estão calibrados radiometricamente (BRAUN, 2020; ESA, 2021).

Existem três convenções de coeficiente de retrodispersão: β° (*beta naught*), σ° (*sigma naught*) e γ° (*gamma naught*). Estas levam em consideração distintas áreas de referência de retrodispersão, de modo que β° trata do plano do alcance inclinado, σ° trata do terreno modelado por um elipsóide terrestre e γ° leva em conta o plano perpendicular à direção de visada local (ATWOOD *et al.*, 2012).

2.3.6 Ruído *Speckle* e Filtro Espacial

O ruído *speckle*, também conhecido como efeito *salt-and-pepper*, é inerente a qualquer imagem SAR. O ruído em questão apresenta características granulares e é originado por meio da interferência dos múltiplos ecos de dispersão e de suas aleatórias contribuições construtivas e destrutivas que ocorrem em cada pixel da imagem. O ruído *speckle* é essencialmente uma forma de ruído que degrada a qualidade da imagem tornando a sua interpretação mais difícil. É possível reduzir este ruído por meio da técnica de *multilooking* ou de um filtro espacial (SARAIWA, 2015).

O filtro espacial é constituído pelo movimento de um elemento intitulado estruturante sobre a imagem, aplicando um tipo de operação, por exemplo uma média, utilizando os valores dos pixels sob o elemento estruturante e substituindo o pixel central da imagem pelo novo valor. Como o elemento estruturante percorre toda a imagem, obtém-se uma imagem mais suave devido à redução do ruído, fazendo com que a resolução espacial seja degradada (SARAIWA, 2015).

2.3.7 Distorções Geométricas e Correções de Terreno

Os intervalos de distância representados nas imagens do sistema SAR são passíveis de distorções em razão das variações topográficas e da geometria de aquisição lateral do sensor. Distorções como essas podem ser observadas nos objetos que não estão diretamente na posição nadiral do sensor. Em relação ao efeito de espelhamento nas imagens SAR, este é causado devido ao sentido de passagem do satélite (ESA, 2021).

Há formas de compensar essas distorções geométricas ao se aplicarem correções de terreno que possibilitem que a geometria representada na imagem corresponda à mais próxima possível da realidade. O processo de correção de terreno é definido pela geocodificação da imagem SAR através da correção de distorções geométricas, fazendo uso de um Modelo Digital de Elevação (MDE). Este procedimento permite corrigir os efeitos relacionados às distorções geométricas, tal como o encurtamento (*foreshortening*), o cavalgamento (*layover*) e a sombra (ESA, 2021).

2.3.8 Missão Sentinel-1

Nesta seção serão exibidos os conhecimentos coletados referentes à Missão Sentinel-1.

2.3.8.1 Características Principais

O Sentinel-1 é uma missão imageadora de radar de abertura sintética que fornece imagens contínuas para quase todos os climas, dia e noite, utilizando a Banda C (3,8 – 7,5 cm). A missão é composta por uma constelação de dois satélites de radar, Sentinel-1A e Sentinel-1B, compartilhando o mesmo plano orbital. Essa constelação oferece alta confiabilidade, melhor tempo de revisita, cobertura geográfica e rápida disseminação de dados para apoiar aplicações operacionais nas áreas prioritárias de monitoramento marinho, monitoramento terrestre e serviços de emergência. O conjunto de dados provenientes da missão Sentinel-1 são viabilizados de forma gratuita, com uma resolução temporal de 12 dias, com o objetivo de aumentar a investigação científica e promover o crescimento de mercados de observação da Terra (ESA, 2021).

Esta missão é descrita como sendo o Observatório de Radar Europeu para a iniciativa conjunta Copernicus da Comissão Europeia (*European Commission* – EC) e da Agência Espacial Europeia (*European Space Agency* – ESA). Copernicus é uma iniciativa europeia para a implementação de serviços de informação relacionados com ambiente e segurança. É baseada em dados de observação recebidos de satélite de observação da Terra e informações baseadas em solo (ESA, 2021).

A missão Sentinel-1 inclui imagens de banda C (C-SAR) operando em quatro modos de imagem exclusivos com diferentes resoluções (até 5 m) e cobertura (até 400 km). Neste processo é fornecida a capacidades de polarização dupla (VV/VH), períodos curtos de revisita, e uma rápida entrega do produto. Para cada observação, medições precisas da posição e atitude da nave espacial estão disponíveis (ESA, 2021).


Os satélites da missão foram projetados para funcionar em um modo de operação pré-programado e livre de conflitos, gerando imagens de todas as massas de terra globais, zonas costeiras e rotas de navegação em alta resolução. Desta forma é assegurada a confiabilidade do serviço exigida pelos serviços operacionais e um arquivo de dados consistente de longo prazo criado para aplicações baseadas em séries temporais longas (ESA, 2021).

2.3.8.2 Modos de Aquisição

Os dados podem ser adquiridos pelo instrumento SAR/Sentinel-1 em quatro modos exclusivos (ESA, 2021):

- *Stripmap* (SM);
- *Interferometric Wide* (IW);
- *Extra-Wide Swath* (EW); e
- *Wave* (WV).

Figura 9 – Representação dos diferentes modos de aquisição do Sentinel-1.



Fonte: ESA (2021).

Dentre as classificações citadas, destaca-se o modo de varredura *Interferometric Wide* (IW) que corresponde ao modo principal de aquisição em terra, visto que atende à maioria das exigências de serviço. A partir deste método é possível adquirir dados com uma faixa de 250 km com resolução espacial de 5 m por 20 m (*single look*). O modo IW captura três sub-faixas usando a Observação do Terreno com Varreduras Progressivas SAR (*Terrain Observation with Progressive Scans SAR – TOPSAR*). Com a técnica TOPSAR o feixe de radiação é direcionado na faixa de imageamento e também é direcionado eletronicamente de trás para frente na direção do azimute para cada ruptura (*burst*) entre imagens, evitando recortes e resultando em qualidade de imagem homogênea em toda a faixa de imageamento (ESA, 2001).

2.3.8.3 Níveis de Processamento e Tipos de Produto

Os produtos de dados Sentinel-1 adquiridos nos modos SM, IW e EW que são gerados pelo centro de operações PDGS (*Payload Data Ground Segment*) são distribuídos em três níveis de processamento (ESA, 2021):

- *Level-0* (L0);
- *Level-1* (L1); e
- *Level-2* (L2).

Os dados focados no *Level-1* (L1) são os produtos destinados à maioria dos usuários de dados. O produto de *Level-0* (dados brutos) é transformado em um produto de *Level-1* pelo *Instrument Processing Facility* (IPF) por meio da aplicação de vários algoritmos. As etapas de processamento envolvidas para produzir produtos de dados de *Level-1* incluem pré-processamento, estimativa de centroide Doppler, foco complexo de visada única (*single look*) e imagem e pós-processamento para geração de produtos SLC e GRD (ESA, 2021).

Os dados de *Level-1* (L1) são capazes de serem processados em produtos *Single Look Complex* (SLC) e/ou *Ground Range Detected* (GRD). Os produtos *Single Look Complex* (SLC) mantêm as informações de fase e também são processados no espaçamento natural do pixel. Os produtos *Ground Range Detected* (GRD), por sua vez, contêm a amplitude detectada e também são multi-visados (*multi-looking*) para garantir que o impacto do ruído *speckle* seja diminuído (ESA, 2021).

Os produtos de *Level-1* GRD consistem em dados de SAR focalizados que foram detectados, multi-visados e projetados no alcance do solo usando o modelo de elipsoide terrestre WGS84. A projeção elipsoide dos produtos GRD é corrigida usando a altura do terreno especificada na anotação geral do produto. A altura do terreno usada varia em azimuth, mas é constante em alcance. As coordenadas no alcance do solo são as coordenadas do alcance inclinado (*slant range*) projetadas no elipsoide da Terra. Os valores de pixel representam a amplitude detectada. As informações da fase são perdidas. O produto resultante tem pixels de resolução aproximadamente quadrados e espaçamento de pixels quadrados com o ruído *speckle* reduzido a um custo de resolução espacial reduzida (ESA, 2021).

2.3.8.4 Resoluções do Sentinel-1

As resoluções espaciais são dependentes diretamente do modo de aquisição e do nível de processamento. Os produtos de Nível-1 GRD estão disponíveis em uma das três resoluções espaciais (ESA, 2021):

- *Full Resolution* (FR) para o modo SM;
- *High Resolution* (HR) para os modos SM, IW e EW;
- *Medium Resolution* (MR) para os modos SM, IW, EW and WV.

A Tabela 3 mostra a resolução em alcance (“rg”) e azimutal (“az”) dos produtos de *Level-1* GRD de Alta Resolução (HR), com a resolução em alcance sendo o alcance do solo.

Tabela 3 – Resolução dos produtos de *Level-1* GRD de Alta Resolução (HR).

Modo	Resolução rg x az	Espaçamento de pixel rg x az	Núm. de visadas
SM	23x23 m	10x10 m	6x6
IW	20x22 m	10x10 m	5x1
EW	50x50 m	25x25 m	3x1

Fonte: Adaptado de ESA (2021).

2.3.9 Missão Sentinel-2

Nesta seção serão exibidos os conhecimentos coletados referentes à Missão Sentinel-2.

2.3.9.1 Características Principais

Sentinel-2 é uma missão europeia de imageamento ótico multiespectral de alta resolução e ampla faixa, utilizando o sensor MSI (*MultiSpectral Instrument*). A especificação completa da missão dos satélites gêmeos Sentinel-2A e Sentinel-2B voando na mesma órbita, mas em fases a 180°, foi projetada para potencializar a frequência de revisita, sendo esta de 5 dias no Equador. A missão em questão apoia os estudos de Monitoramento Territorial da Copernicus, incluindo o monitoramento da cobertura vegetal, do solo e da água, bem como a observação de cursos d’água interiores e de zonas costeiras (ESA, 2021).

2.3.9.2 Níveis de Processamento e Tipos De Produto

Todos os dados adquiridos pelo sensor MSI são sistematicamente processados para o *Level-1C* pelo PDGS. O processamento de *Level-1* usa dados consolidados de *Level-0* (dados brutos) como entrada. O processamento de nível 1C inclui correções radiométricas e geométricas, incluindo ortorretificação e registro espacial em um sistema de referência global com precisão de sub-pixel. Os produtos são uma compilação de grânulos elementares de tamanho fixo, dentro de uma única órbita. Um grânulo é a partição mínima indivisível de um produto (contendo todas as bandas espectrais possíveis) (ESA, 2021).

Existem disponíveis para os usuários dois tipos de produtos:

- *Level-1C* (L1C); e
- *Level-2A* (L2A).

No que concerne ao *Level-1C* e o *Level-2A*, os grânulos, também chamados de blocos, correspondem a ortoimagens de 100x100km² em projeção UTM/WGS84. O produto *Level-1C* é composto por blocos de 100x100 km² (ortoimagens em projeção UTM / WGS84). Este produto resulta do uso de um Modelo Digital de Elevação (MDE) utilizado para o processo de ortorretificação dos produtos L1C, denominado *Copernicus DEM GLO-90m*, para que a imagem seja projetada em geometria cartográfica. Medições radiométricas por pixel são fornecidas em refletâncias do Topo da Atmosfera (*Top Of Atmosphere – TOA*) juntamente com os parâmetros para transformá-los em radiâncias. Os produtos de nível *Level-1C* são reamostrados com uma distância de amostragem do solo (*Ground Sampling Distance – GSD*) constante de 10, 20 e 60 m, dependendo da resolução nativa das diferentes bandas espectrais. Em produtos de *Level-1C*, as coordenadas de pixel se referem ao canto superior esquerdo do pixel (ESA, 2021).

2.3.9.3 Resoluções do Sentinel-2

O Sentinel-2 possui uma carga útil de instrumento ótico MSI que realiza a amostragem por meio de 13 bandas espectrais, sendo quatro bandas em 10 m, seis bandas em 20 m e outras três bandas em 60 m de resolução espacial. Estas bandas espectrais variam do visível (*Visible* – VNIR) e do infravermelho próximo (*Near Infra-Red* – NIR) ao infravermelho de ondas curtas (*Short Wave Infra-Red* – SWIR). A largura da faixa orbital é de 290 km (ESA, 2021).

Tabela 4 – Comprimentos de onda e larguras de banda das três resoluções espaciais dos instrumentos MSI.

Resolução espacial (m)	Número da banda	S2A		S2B	
		Comprimento de onda central (nm)	Largura de banda (nm)	Comprimento de onda central (nm)	Largura de banda (nm)
10	2	492,4	66	492,1	66
	3	559,8	36	559,0	36
	4	664,6	31	664,9	31
	8	832,8	106	832,9	106
20	5	704,1	15	703,8	16
	6	740,5	15	739,1	15
	7	782,8	20	779,7	20
	8A	864,7	21	864,0	22
	11	1613,7	91	1610,4	94
	12	2202,4	175	2185,7	185
60	1	442,7	21	442,2	21
	9	945,1	20	943,2	21
	10	1373,5	31	1376,9	30

Fonte: Adaptado de ESA (2021).

2.4 CLASSIFICAÇÃO SUPERVISIONADA

A classificação de imagens tem como objetivo o reconhecimento de padrões e o relacionamento de um objeto na imagem com uma classe temática, por meio de uma análise quantitativa do espaço de atributos da imagem (CRÓSTA, 1992; MATHER; TSO, 2009). Dito de outra forma, classificar as imagens é realizar a análise das propriedades espectrais de diversas feições que são exibidas na imagem multiespectral, e organizar os dados espectrais em categorias ou classes espectralmente semelhantes, fazendo uso de regras de decisão numérica pré-definidas (ROSOT, 2001).

Para a execução de uma classificação supervisionada é necessária ser feita a seleção de amostras pelo próprio analista, que utiliza de conhecimentos prévios obtidos sobre a área de estudo para definição das classes temáticas e amostras. O usuário responsável pela análise se encarrega da seleção de pixels que representam feições ou padrões de cobertura do solo que são reconhecidas ou que podem ser identificadas com a ajuda de outras fontes distintas de informação, tais como fotos aéreas, mapas e verdade de campo (ERDAS, 1997; ROSOT, 2001). Nesse caso, as amostras que foram coletadas são a base para a classificação dos demais pixels que não possuem uma classe temática definida (DINIZ, 2019; MATHER, 1999). A classificação supervisionada corresponde a uma das técnicas que são mais usadas no Sensoriamento Remoto para se fazer uma análise quantitativa de dados (DINIZ, 2019).

No contexto da classificação supervisionada para uma dada classe a área de treinamento respectiva deve ser uma amostra homogênea, todavia, precisa ser incluída toda a abrangência de variabilidade para a classe em questão (SCHOWENGERDT, 1997). Em função disto, é necessário que sempre seja usada mais de uma amostra de treinamento por classe. Por meio do exercício de identificação de padrões, o usuário pratica uma espécie de “treino” do sistema para que discrimine pixels com características semelhantes (ROSOT, 2001).


O ideal é que as amostras selecionadas sejam capazes de expressar a variabilidade de cada categoria dentro da área estudada. No que tange ao número de unidades de amostra de treinamento que são necessárias para que se ocorra uma classificação supervisionada, é recomendado um mínimo de $(N+1)$ unidades de amostra para que se represente de forma legítima cada classe supervisionada, sendo N o número de bandas que compõem a imagem (RICHARD, 1986; ROSOT, 2001; VENTURIERI; SANTOS, 1998).

2.4.1 Classificador *Random Forest*

O *Random Forest* (RF) corresponde a um classificador de aprendizagem de máquina (*machine learning*) cujo uso vem sido amplamente difundido ao longo das últimas décadas devido ao seu processamento veloz e à sua capacidade de gerar excelentes resultados de classificação (BREIMAN, 2001; PAL, 2005). O classificador *Random Forest* é originado a partir de uma regra de decisão não-paramétrica, isto significa que não é fundamentado em estatísticas e, por isso, não tem dependência direta das propriedades dos dados (ERDAS, 1997).

Este classificador utiliza um conjunto de árvores de decisão para inferir uma previsão. Estas árvores de decisão são criadas independentemente, através de um subconjunto de amostras de treinamento (Figura 10). A divisão de cada nó é realizada através de recursos definidos pelo próprio usuário (BELGIU; DRAGUT, 2016; BREIMAN, 2001; LU; WENG, 2007).

Figura 10 – Fases de treinamento e classificação do algoritmo *Random Forest*.



Fonte: Belgiu e Dragut (2016).

A partir da Figura 10 são obtidas as definições dos parâmetros a seguir: i = amostras; j = variáveis; p = probabilidade; c = classe; s = data; t = número de árvores; d = novo dado a ser classificado e $value$ = possíveis valores assumidos pela variável j (DINIZ, 2019).

Para que sejam geradas as árvores de decisão, é necessário determinar dois parâmetros fundamentais, que são eles o número referente às árvores que serão produzidas ($Ntree$) e o número de variáveis que virão a ser testadas ($Mtry$). Com o aumento do número das árvores de decisão ($Ntree$), o algoritmo faz com que sejam criadas árvores com alta variação e baixa correlação, de modo a evitar que o classificador se oriente de forma tendenciosa para determinada classe. De forma posterior, estas árvores geradas podem ser usadas na classificação de novos alvos (BELGIU; DRAGUT, 2016; BREIMAN, 2001).

Utilizar algoritmos de aprendizagem de máquina como o *Random Forest* para mapear o uso e a cobertura da superfície terrestre se mostra justificável devido à sua possibilidade de aplicação em sensores distintos, e também por revelar excelentes resultados em relação a outros classificadores que são usualmente utilizados, especialmente no caso de imagens de radar por serem não-paramétricos (DINIZ, 2019).

2.4.2 Validação do Desempenho Classificatório

A análise dos resultados obtidos com as classificações é realizada através da matriz de confusão e de análises estatísticas como o índice Kappa. A matriz de confusão representa uma das formas de avaliar a exatidão ou acurácia de uma classificação, através da comparação entre os resultados da classificação e dados de referência, desta forma, é possível observar se os pixels foram corretamente classificados, além de se obter os erros de comissão e de omissão (CONGALTON; GREEN, 1999; DINIZ, 2019; MATSUKUMA, 2002).

A matriz de confusão, também denominada como a matriz de erros, possui a forma de uma matriz quadrada que dispõe das dimensões $c \times c$, na qual c refere-se ao número de classes. Nas colunas da matriz estão representados o número de pixels amostrados para cada classe segundo a verdade de campo ou amostra de referência. Nas linhas estão representados o número de pixels encontrados para cada classe segundo a classificação automática. Sendo assim, a diagonal principal da matriz conterá o número de pixels classificados corretamente para cada categoria, logo possibilitando o cálculo da precisão e acurácia de cada uma das classes temáticas. A partir desta matriz é possível inferir algumas medidas descritivas, sendo elas a Acurácia Global (AG), a Acurácia do Utilizador (AU) e a Acurácia do Produtor (AP) (LILLESAND; KIEFER, 1994; ROSOT, 2001):

- Acurácia Global (AG): corresponde à razão entre o número total de pixels que foram corretamente classificados e o número total de pixels de referência;
- Acurácia do Produtor (AP): corresponde à razão obtida entre o número de pixels corretamente classificados em cada uma das categorias (na diagonal principal) e o número verdadeiro de pixels que pertencem àquela categoria (o total da coluna). É uma medida que indica a probabilidade dos pixels pertencentes a uma categoria conhecida no terreno (pixels de referência) terem sido corretamente classificados e reflete erros de omissão;

- Acurácia do Usuário (AU): corresponde à razão entre o número de pixels classificados corretamente em cada categoria (na diagonal principal) e o número total de pixels classificados naquela categoria (o total da linha). É uma medida que denota a probabilidade de que um pixel classificado em uma certa categoria realmente represente aquela categoria no terreno e reflete erros de comissão.

Uma das variáveis que podem ser inferidas e quantificadas por meio da matriz de confusão é o índice ou coeficiente Kappa. Este índice expõe o nível de concordância entre os dados utilizados como referência e os dados classificados, o que confere um aspecto de confiabilidade e precisão dos dados classificados. O índice Kappa gera valores que podem variar de 0 a 1, de modo que quanto maior a aproximação de 1, indica maior grau de concordância entre o dado de referência e o dado classificado (PERROCA; GAIDZINSKI, 2003). A estimativa do coeficiente é baseada na diagonal principal em conjunto com os totais marginais da linha e da coluna (FOODY, 2020). O índice pode ser obtido através da Equação 5:

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

onde n é o número de pixels classificados que foram comparados com os dados de referência, i é o número da classe, n_{ii} é o número de pixels pertencentes à classe de referência i que foram classificados como classe i (diagonal da matriz), n_{+i} é o número total de pixels classificados pertencentes à classe i e n_{i+} é o número total de pixels de referência pertencentes à classe i (SARAIVA, 2015).

O coeficiente Kappa é um índice ainda amplamente utilizado em Sensoriamento Remoto para validação do desempenho classificatório. Neste presente trabalho, este coeficiente foi usado na validação do desempenho dos resultados das classificações. Destaca-se, porém, que Foody (2020) apresenta o coeficiente Kappa como um índice não muito adequado para descrever a acurácia da classificação, pois ele é tratado como sendo a medida do nível de concordância observado além da probabilidade que é obtida usando um modelo de probabilidade que é inadequado para o cenário típico de avaliação da acurácia. Recomenda-se que em outros trabalhos, seja observado o que Foody (2020) recomenda para validação do desempenho de classificação de imagens de Sensoriamento Remoto.

Pode-se avaliar o desempenho de uma classificação segundo os valores do coeficiente Kappa obtidos com base nos intervalos mostrados na Tabela 5 abaixo. Nesta tabela são apresentadas três escalas de interpretação do coeficiente Kappa. Estas escalas são fornecidas por Landis e Koch (1977); Fleiss *et al.* (2013); e Monserud e Leemans (1992). As escalas possuem foco apenas nos valores positivos (FOODY, 2020; SARAIVA, 2015).

Tabela 5 – Desempenho da classificação segundo o coeficiente Kappa.


	Landis e Koch	Fleiss <i>et al.</i>	Monserud e Leemans
1.0	Quase perfeito	Excelente	Excelente ^{Perfeito}
0.8	Substancial	Razoável a Bom	Muito bom
0.6	Moderado		Bom
			Razoável
0.4	Razoável	Ruim	Ruim
0.2	Fraco		Muito ruim
0.0	Ruim		Nada

Fonte: Adaptado de Foody (2020).

3 MATERIAIS E MÉTODOS

Nesta seção serão descritos de forma detalhada os dados, *softwares* e aplicativos, e procedimentos metodológicos utilizados para realização do trabalho.

Figura 11 – Fluxograma representando a metodologia adotada.




Fonte: O autor (2021).

3.1 ÁREA DE ESTUDO

A área de estudo compreende toda a faixa costeira do município de Jaboatão dos Guararapes, e também parte da faixa costeira dos municípios de Recife e Cabo de Santo Agostinho, todos estes municípios pertencentes ao estado de Pernambuco, Brasil. Corresponde a uma área total de cerca de 16.200 hectares, e está situada entre as coordenadas $8^{\circ} 8' 45''$ e $8^{\circ} 16' 27''$ de latitude sul e $34^{\circ} 53' 14''$ e $34^{\circ} 59' 30''$ de longitude oeste. Esta área foi escolhida por oferecer diferentes tipos de alvos para classificação.

Figura 12 – Mapa de localização da área de estudo.



Fonte: O autor (2021).

Segundo a classificação climática de Köppen (1928), a área de estudo se situa numa região de transição entre os climas Ams' e As' (clima tropical quente e úmido com taxa de precipitação superando a de evaporação). A área está situada numa região de clima tropical, com temperaturas médias entre 32 °C de máxima e 18 °C de mínima. O volume de precipitação médio anual da região é de cerca de 1.720 mm, com a maior concentração sendo observada entre os meses de maio e agosto, caracterizando o período chuvoso. O período seco é caracterizado pelos meses de outubro a março, onde o volume diminui consideravelmente, com setembro e abril sendo os meses de transição entre os períodos distintos (NOBREGA; FARIAS, 2016). Por estar nessas condições, representa uma área com uma constante cobertura de nuvens, que está de acordo com a problemática exposta neste trabalho.

Para a produção do mapa presente na Figura 12 foi utilizada uma composição RGB 432 com realce de contraste através das imagens óticas do satélite Sentinel-2A. Foi selecionada a imagem de um dia que não apresentasse nuvens na área para que fosse possível serem escolhidas as amostras de treinamento.

A área de estudo é caracterizada por apresentar uma extensa área urbanizada, representada por áreas urbanas dos bairros de Piedade, Prazeres, Guararapes, Muribeca, Comportas, Cajueiro Seco, Candeias e Barra de Jangada em Jaboatão dos Guararapes; e Pontezinha e Ponte dos Carvalhos no Cabo de Santo Agostinho.

A cobertura vegetal da área apresenta vegetação nativa representada por restos da antiga Mata Atlântica e vegetação de manguezal. Também podem ainda ser encontradas áreas sem cobertura vegetal, que estão situadas principalmente nos limites das concentrações urbanas. A área de estudo é cortada pelo Rio Jaboatão e compreende a Lagoa Olho D'Água (CPRM, 1997; MAPBIOMAS, 2021).

São identificadas duas unidades de relevo na área em estudo: planície costeira onde que apresenta terraços marinhos com altitudes variando de 1 a 8 metros aproximadamente e, uma área com altitudes mais elevadas, podendo atingir mais 60 metros (Apêndice A), formada por rochas cristalinas recobertas ou não por sedimentos terciário-quadernários da Formação Barreiras, ou sedimentos cretácicos da Formação Cabo (CPRM, 1997).

3.2 DADOS E SOFTWARES UTILIZADOS

Todas as imagens de satélite foram obtidas através da plataforma *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/dhus/#/home>), administrada pela ESA. A data de detecção e aquisição das imagens pelos satélites Sentinel-1 e Sentinel-2 foi de 03/11/2020 pois é o período de seca na região e neste dia a área de estudo não apresentava nuvens, assim sendo possível gerar os índices por diferença normalizada e escolher as amostras de treinamento para a classificação supervisionada.

Tabela 6 – Dados das imagens adquiridas do Sentinel-1A.

Instrumento/Satélite	C-SAR/Sentinel-1A
Órbita Absoluta	035081
Órbita Relativa	09
Direção de Passagem	Descendente
Data de aquisição da imagem	03/11/2020
Resolução espectral	Banda C
Modo de Aquisição	IW
Nível de Processamento/Classe do Produto	L1/Standard
Tipo do Produto/Classe de Resolução	GRD/High
Polarização	Dual VV/VH
Resolução Espacial Alcance x Azimute	20 x 22 m
Resolução Espacial do pixel	10 m
Resolução Temporal	12 dias
Fonte	ESA (2021)

Fonte: O autor (2021).

Tabela 7 – Dados das imagens adquiridas do Sentinel-2A.

Instrumento/Satélite	MSI/Sentinel-2A
Órbita Absoluta	028034
Órbita Relativa	09
Identificador do Bloco	25LBL
Direção de Passagem	Descendente
Data de aquisição da imagem	03/11/2020
Hora de aquisição	12:43:21 (GMT)
Tipo do Produto	Level-1C
Resolução Espectral	13 bandas (VNIR; NIR; SWIR)
Resolução Espacial	10 m; 20 m; 60 m
Resolução Radiométrica	12 bits
Resolução Temporal	10 dias
Fonte	ESA (2021)

Fonte: O autor (2021).

Para a análise, processamento e classificação das imagens de radar do Sentinel-1 e óticas do Sentinel-2, e coleta de dados em campo, foram utilizados os *softwares* apresentados na Tabela 8. A imagem referente à área de estudo nas polarizações VH e VV pode ser vista no Apêndice B.

Tabela 8 – *Softwares* utilizados na metodologia do trabalho.

	QGIS Desktop versão 3.10.14	- Processamento das imagens - Pós-classificação - Matriz de confusão e índice kappa - Cálculo de áreas das classes
	SNAP Desktop versão 8.0.0	- Processamento das imagens - Classificação supervisionada - Validador das Amostras
	Google Earth Pro versão 7.3.4	- Apoio para seleção das amostras de referência
	Aplicativo Maverick: GPS Navigation versão 2.8	- Coleta de coordenadas em campo

Fonte: O autor (2021).

3.2.1 Material de Apoio Auxiliar

Para auxiliar na determinação da discriminação da verdade terrestre da área de estudo e seleção das amostras de referência para a classificação, foram adquiridas ortofotos e Modelo Digital de Elevação (MDE), exibido no Apêndice A, que cobrissem toda a área de estudo, ambos em escala 1:5000 (resolução espacial de 1 m) disponibilizados pela Agência Pernambucana de Águas e Clima (APAC) obtidos a partir de um perfilamento laser realizado no estado de Pernambuco no ano de 2016 pelo Programa Pernambuco Tridimensional (PE3D).

Também, para o mesmo propósito, foi realizado um levantamento em campo no dia 22/10/2021 para a coleta de dados, utilizando o aplicativo Maverick para adquirir as coordenadas geográficas, em 7 pontos diferentes escolhidos por se encontrarem em regiões que apresentaram um comportamento distinto quando realizada uma combinação das imagens de bandas de polarização do radar, para ser possível também avaliar a causa do comportamento distinto. O resultado do levantamento em campo pode ser observado no Apêndice C.

3.3 PROCESSAMENTO DAS IMAGENS

Nesta seção será mostrado o procedimento completo para a execução do processamento das imagens.

3.3.1 Imagens do sensor ótico

No processamento das imagens óticas utilizando o *software* QGIS, inicialmente foi selecionada a subárea correspondente à área de estudo através de um recorte das bandas espectrais 2, 3, 4 e 8 com resolução espacial de 10 m e das bandas espectrais 5, 6, 7, 8A, 11 e 12 com resolução espacial de 20 m, do sensor MSI do satélite Sentinel-2A. Então, todas essas 10 bandas foram reprojetaadas para o Sistema de Referência de Coordenadas (SRC) SIRGAS 2000/UTM zone 25S, sendo que as bandas com resolução espacial de 20 m tiveram seus pixels reamostrados pelo método de reamostragem do vizinho mais próximo para uma resolução espacial de 10 m.

Logo foi feito uma mesclagem, ou seja, um empilhamento de todas essas 10 bandas para que se tornassem um único arquivo de empilhamento, onde cada banda estaria salva separadamente dentro desse arquivo.

Com o arquivo contendo as 10 bandas empilhadas e utilizando o complemento SCP (*Semi-Automatic Classification Plugin*) presente no QGIS, foi feita a calibração radiométrica para que os números digitais fossem convertidos para reflectância aparente a partir dos coeficientes de calibração das bandas espectrais assim sendo geradas as bandas de reflectância aparente correspondentes à cada banda inserida. Em seguida foi aplicada a correção atmosférica pelo o método DOS1 (*Dark Object Subtraction 1*), método no qual a interferência atmosférica é estimada diretamente a partir da imagem de satélite, onde a absorção atmosférica é ignorada e não existe a necessidade de se obter dados sobre as condições atmosféricas na data de obtenção das imagens (CALIXTO *et al.*, 2017), gerando assim um arquivo de empilhamento de 10 bandas de reflectância de superfície (corrigidas atmosféricamente), denominado como arquivo pós-processado de dados óticos.

Os índices NDVI, NDWI e NDBI foram produzidos a partir das bandas específicas, após serem transformadas em imagens de reflectância de superfície. O resultado do cálculo dos índices é apresentado no Apêndice D.

3.3.2 Imagens do sensor de radar

Para o processamento das imagens de radar utilizando o *software* SNAP, primeiramente foi selecionada a subárea correspondente à área de estudo através de um recorte das bandas de polarização VH e VV, do sensor SAR do satélite Sentinel-1A. Então foi realizada a calibração radiométrica para conversão do valor de pixel em retroespalhamento (σ°), seguido da aplicação do filtro adaptativo Lee Sigma para a redução do ruído *Speckle* utilizando uma janela de tamanho 7x7 assim suprimindo variações aleatórias e melhorando a qualidade da imagem, preservando sua nitidez e detalhes. Após foi feita a ortorretificação *Range-Doppler* por meio do Modelo Digital de Elevação SRTM 3Sec (*Shuttle Radar Topography Mission*) de 30m já incorporado no pacote de ferramentas do SNAP, para a correção geométrica. A correção geométrica foi realizada de forma a não mascarar as áreas sem elevação para que a região do oceano não fosse suprimida na imagem.

Para obter uma distribuição de valores mais normal, a função de conversão de valores em escala de decibéis é aplicada à imagem de radar. Ela traduz os valores de pixel em uma escala logarítmica e resulta em contrastes mais altos, porque os valores de brilho são deslocados em direção à média, enquanto os valores de escuro se estendem por uma faixa mais ampla. O resultado quando exportado, gera um arquivo com as bandas polarizadas VH e VV já processadas e empilhadas, no Sistema de Referência de Coordenadas WGS84. Então esse arquivo de empilhamento foi reprojetoado para o SRC SIRGAS 2000/UTM zone 25S (pixels reamostrados para resolução espacial de 10m), que é o sistema de referência de coordenadas utilizado no trabalho, gerando um produto denominado arquivo pós-processado de dados de radar.

3.4 CLASSIFICAÇÃO SUPERVISIONADA


Nesta seção será mostrado o procedimento completo para a execução da classificação supervisionada.

3.4.1 Definição das Classes Temáticas do Mapeamento e Amostras de Treinamento

Com o objetivo de incluir na classificação supervisionada todos os objetos e feições presentes na área de estudo, foram definidas 4 classes temáticas:

- Infraestrutura urbana: Classe representada pelos centros urbanos com predomínio de superfícies não vegetadas, incluindo estradas, vias e construções;
- Corpos hídricos: Classe representada pelos corpos hídricos incluindo lagoas, rios e oceano;
- Área vegetada: Classe representada pelas áreas que apresentam algum tipo de cobertura vegetal; e
- Área não-vegetada: Classe representada pelas áreas que não apresentam nenhum tipo de cobertura vegetal e que não se enquadram nas classes anteriores.

Figura 13 – Representação dos alvos para cada classe temática.




Fonte: O autor (2021).

As amostras de treinamento foram geradas através de polígonos das regiões de interesse (*Regions Of Interest* – ROIs). Para selecionar os polígonos referentes a cada classe através de técnicas de fotointerpretação, foram utilizadas como material de referência para discriminação dos alvos os seguintes materiais:

- Composição RGB 432 com realce de contraste, das bandas espectrais empilhadas e processadas do Sentinel-2A;
- Composição RGB VH-VV-VH, das bandas de polarização empilhadas e processadas do Sentinel-1A (Figura 17-A);
- NDVI para realce da classe Área vegetada;
- NDWI para realce da classe Corpos hídricos; e
- NDBI para realce da classe Infraestrutura urbana.

Foram produzidos ao total 105 polígonos de amostras de treinamento, distribuídos por toda a região de estudo, armazenados como dados geoespaciais em forma de vetor (*shapefiles*).

Figura 14 – Polígonos das amostras de treinamento para a classificação.



Fonte: O autor (2021).

3.4.2 Execução da Classificação Supervisionada

A classificação supervisionada através do algoritmo *Random Forest* foi realizada utilizando o *software* SNAP, tanto para o arquivo pós-processado de dados óticos quanto para o arquivo pós-processado de dados de radar, utilizando a mesma quantidade de árvores de decisão a serem geradas para que as duas classificações e tornassem comparáveis.

Os classificadores no SNAP suportam a entrada de vários produtos como camadas de entrada para a classificação. Após serem inseridas as camadas de entrada e os polígonos de treinamento (polígonos das amostras) e iniciado o processo de classificação, o classificador *Random Forest* extrai todos os pixels compreendidos pelos polígonos de treinamento e tenta encontrar limites (*thresholds*) que permitam separar os diferentes tipos de entrada da melhor forma possível. Assim que o processamento é finalizado, é criado um novo produto contendo uma banda que é o resultado da classificação e a banda de confiança como subproduto da classificação (BRAUN, 2020).

Durante o processamento pode ser gerado um arquivo de texto denominado Validador das Amostras (*Evaluate classifier*) que fornece informações sobre o quão bem o conjunto de regras do classificador foi capaz de descrever os dados de treinamento com base nas bandas e camadas de entrada. Ele não valida a acurácia de toda a classificação, mas apenas o quão bem os dados de treinamento foram classificados com base no limiar hierárquico do classificador *Random Forest* (BRAUN, 2020).

Referente ao arquivo pós-processado de dados óticos, este foi importado para o *software* SNAP, resultando em um arquivo com 10 camadas de entrada, em conjunto com o arquivo vetorial dos polígonos de amostras de treinamento criado anteriormente. Para o processo de classificação foi selecionado o valor de 25 árvores a serem geradas para aumentar o número de iterações e tornar a predição mais robusta.

Em relação ao arquivo pós-processado de dados de radar, este foi importado para o *software* SNAP, resultando em um arquivo com 2 camadas de entrada, simultaneamente com o arquivo vetorial dos polígonos de amostras de treinamento criado anteriormente. Segundo Breiman (2001), a classificação também funciona em qualquer dado e quantidade de entrada, mas o classificador *Random Forest* requer um número maior de bandas de entrada, porque usa repetidamente subconjuntos aleatórios das bandas de entrada e os pixels de treinamento para encontrar os limites mais robustos com base nas feições de entrada com a maior importância de previsão.

Devido à essa necessidade, alguns parâmetros foram calculados para aumentar a quantidade e aprimorar a qualidade dos dados de entrada, consequentemente melhorando o resultado da classificação. São eles:

- *Análise dos componentes principais (Principal Component Analysis – PCA)*: É uma técnica que identifica redundâncias e diferenças em um arquivo de bandas empilhadas e as transforma em novas bandas não correlacionadas (componentes principais) com conteúdo de informação maximizado. Como resultado, o primeiro componente principal (PC1) representa a proporção máxima de variação da pilha original. A variação restante é expressa por PC2, PC3 e assim por diante (BRAUN, 2020).
- *Geração de texturas (Grey Level Co-occurrence Matrix – GLCM)*: As texturas de imagem são derivativos métricos que descrevem padrões espaciais locais de uma imagem em tons de cinza de forma quantitativa. Eles são especialmente populares para produtos SAR, porque a maioria deles consiste em apenas um número limitado de bandas (polarização única ou dupla). Como as classificações de imagem baseadas em um espaço de bandas uni ou bidimensional muitas vezes não trazem as precisões desejadas, as texturas de imagem são uma forma de aumentar o número de bandas de entrada (ULABY *et al.* 1986). Além disso, são capazes de descrever o grau de ruído *speckle* em diferentes partes da imagem e, portanto, também contribuem para uma melhor separação dos tipos de superfície (BRAUN, 2020). As texturas geradas e usadas foram Homogeneidade, Energia, Probabilidade Máxima, Entropia e Média GLCM.

Agora com um total de 14 bandas de entrada (2 do arquivo pós-processado, 2 componentes principais, 5 texturas da imagem pós-processada VH e 5 texturas da imagem pós-processada VV), o arquivo vetorial das amostras de treinamento e a definição do valor de 25 árvores a serem geradas, o processo de classificação para os dados de radar foi realizado.

3.4.3 Pós-Classificação

A ferramenta *Classification Sieve* presente no plugin SCP do *software* QGIS permite a substituição de valores de pixel isolados pelo valor do maior agrupamento de pixels vizinho, tornando a imagem de classificação menos ruidosa. Neste contexto, um agrupamento de pixels são pixels agrupados que possuem as mesmas características. Esta ferramenta apresenta dois parâmetros:

- Limite de tamanho: tamanho do agrupamento de pixels a ser substituído (em unidade de pixel); todos os agrupamentos de pixels menores que o número selecionado de pixels serão substituídos pelo valor do maior agrupamento de pixels vizinho;
- Conexão de pixels:
 - 4: em uma janela 3x3, pixels diagonais não são considerados conectados;
 - 8: em uma janela 3x3, os pixels diagonais são considerados conectados.

Ambas as imagens de classificação, obtidas pelos dados óticos e pelos dados de radar, foram submetidas a este processo utilizando um limite de tamanho de 25 pixels e uma conexão de pixels de valor 8.

3.4.4 Análise Estatística e Validação da Classificação

Para avaliar a acurácia do treinamento, ou seja, quão bem as amostras de treinamento foram escolhidas, foi feita a análise do arquivo Validador das Amostras gerado para cada classificação, através das métricas de avaliação da acurácia do treinamento disponibilizadas:

- Acurácia;
- Precisão;
- Correlação;
- Taxa de erro;
- Verdadeiro Positivo;
- Falso Positivo;
- Verdadeiro Negativo;
- Falso Negativo;
- Porcentagem de previsões corretas; e
- Erro médio quadrático (*Root-Mean-Square Error* – RMSE).

As seguintes métricas referem-se à distribuição estatística dos pixels de treinamento por classe (x) (BRAUN, 2020):

- Verdadeiro Positivo: Número de pixels que são da classe x e foram atribuídos à classe x. Valores altos indicam que a maioria dos pixels desta classe foram atribuídos de forma confiável.
- Falso Positivo: Número de pixels que são da classe x, mas não foram atribuídos à classe x. Valores altos indicam que essa classe está superestimada na previsão.
- Verdadeiro Negativo: Número de pixels que não são da classe x e não foram atribuídos à classe x. Valores altos indicam que apenas alguns pixels desta classe foram perdidos na previsão.
- Falso Negativo: Número de pixels que não são da classe x, mas foram atribuídos à classe x. Valores altos indicam que essa classe está subestimada na previsão.

Para a avaliação do desempenho da classificação foram coletadas amostras de referência. Estas amostras são assumidas como representativas da verdade terrestre. Para sua aquisição e seleção foram utilizados os seguintes materiais:

- Composição RGB 432 com realce de contraste, das bandas espectrais empilhadas e processadas do Sentinel-2A;
- Índices por Diferença Normalizada;
- Imagens do mês de dezembro de 2020 obtidas pelo *software* Google Earth Pro;
- Ortofotos em escala 1:5000; e
- Coleta de dados em campo.

Foram coletadas 60 amostras de referência evitando os locais que já haviam sido usados na coleta das amostras de treinamento para evitar algum tipo de resultado tendencioso, ou seja, as amostras de referência só foram coletadas nos locais onde não haviam sido coletadas amostras de treinamento. Para reconhecer áreas como representativas da verdade terrestre, foram utilizadas como referência as ortofotos em escala 1:5000 de melhor resolução espacial, o *software* Google Earth Pro configurado para mostrar as imagens do mês de dezembro de 2020; e os dados coletados no levantamento em campo. Apesar de terem sido adquiridas do ano de 2016, as ortofotos mostram muitas áreas que não sofreram alterações no decorrer dos anos. A configuração das amostras de referência na área de estudo pode ser vista no Apêndice E.

De posse das classificações com ruídos reduzidos e das amostras de referência foi possível gerar a matriz de confusão e, a partir dela, o índice Kappa para avaliar a acurácia e o desempenho das classificações.


4 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados encontrados assim como uma discussão acerca do que eles representam.

4.1 ANÁLISES DAS POLARIZAÇÕES VH E VV


As imagens das polarizações VH e VV apresentam como os alvos são exibidos ao interagir com as diferentes polarizações. A Figura 15 demonstra que a polarização VH permite uma maior discriminação das áreas não vegetadas do que a polarização VV. Já na Figura 16 a polarização VV permite uma maior distinção das áreas com infraestrutura urbana do que a polarização VH. Ambas polarizações discriminam bem as áreas com corpos hídricos.

Figura 15 – Polarização VH. A - Antes do processamento; B - Após o processamento.



Fonte: O autor (2021).


Figura 16 – Polarização VV. A - Antes do processamento; B - Após o processamento.



Fonte: O autor (2021).

4.2 ANÁLISE DA COMPOSIÇÃO DAS BANDAS DE RADAR E DO MATERIAL DE APOIO

Figura 17 – A - Composição RGB VH-VV-VH; B - Mosaico de ortofotos.



Fonte: O autor (2021).

O principal motivo para ser realizado a coleta de dados em campo foi o de, além de auxiliar na contestação da verdade terrestre, investigar os diferentes comportamentos apresentados do retroespalhamento dentro das áreas de infraestrutura urbana, mais especificamente nos centros urbanos.

Por ser uma única classe temática, ou seja, possui características semelhantes em diferentes pontos, o parâmetro principal que foi avaliado para entender os diferentes comportamentos do retroespalhamento na classe de infraestrutura urbana foi a polarização.

A partir destas duas fontes de dados presentes na Figura 17, analisando os pontos 1 a 5 nas áreas urbanas, chegou-se à hipótese que quando a orientação das feições é em sua maioria aproximadamente perpendicular à direção de iluminação dos pulsos de micro-ondas do radar, resulta numa coloração magenta, visto que o retroespalhamento é menor nas polarizações cruzadas (polarização VH no canal vermelho e no canal azul). Quando a orientação é aproximadamente paralela, resulta na cor verde, pois a intensidade do retroespalhamento é maior em polarizações paralelas (polarização VV no canal verde).


Essas diferenças entre a resposta das duas polarizações, afeta a interpretação correta do das imagens e consequentemente o resultado da classificação.

As áreas de corpos hídricos se apresentam na coloração preta pois quase toda energia incidente é refletida na direção oposta ao sensor causando o espalhamento especular. As áreas não vegetadas apresentam a coloração mais escura, podendo variar até o preto (pontos 6 e 7) devido principalmente à influência da constante dielétrica. O ponto 6 apresenta vegetação em parte, mas a maioria do espaço em seu entorno representa uma área não vegetada. Já o ponto 7 está localizado em um campo sem nenhum tipo de vegetação ou construção, apenas solo exposto. As fotos dos pontos visitados em campo estão presentes no Apêndice C.

4.3 MAPAS DAS CLASSIFICAÇÕES

A Figura 18 abaixo mostra as imagens de classificação geradas utilizando o algoritmo *Random Forest* e submetidas ao processo de pós-classificação para torná-las menos ruidosas.

Figura 18 – Mapa das pós-classificações. A - A partir dos dados óticos; B - A partir dos dados de radar.



Fonte: O autor (2021).

A Tabela 9 abaixo mostra o valor das áreas em hectares de cada classe nas imagens de pós-classificação, e também a porcentagem de cada classe na área de estudo. É observado que na classificação feita com os dados de radar existe muito mais área não vegetada do que na classificação feita com dados óticos, representando a maior discrepância. Logo após percebe-se a diferença da classe vegetada, que aparece em maior abundância na classificação com dados óticos. As outras classes não apresentaram valores de áreas em hectares tão discrepantes.

Tabela 9 – Áreas das classes temáticas nas imagens de pós-classificação.

	ÓTICO		RADAR		Discrepância (ha)
	Área (ha)	Porcentagem (%)	Área (ha)	Porcentagem (%)	
Área não vegetada	630,57	3,89	2003,13	12,36	1372,56
Área vegetada	4550,27	28,08	3723,56	22,98	826,71
Corpo hídrico	6193,35	38,21	6033,14	37,22	160,21
Infraestrutura urbana	4832,92	29,82	4447,28	27,44	385,64

Fonte: O autor (2021).

4.4 TABELAS ESTATÍSTICAS

Nesta seção serão exibidas as principais tabelas estatísticas geradas a partir dos resultados encontrados.

4.4.1 Validação dos dados de treinamento

As Tabelas 10 e 11 abaixo representam os valores do Validador das Amostras gerado para cada classificação e apresentam as diferentes métricas de acurácia para as 4 classes treinadas.

Tabela 10 – Validador das Amostras para a classificação gerada a partir dos dados óticos.

	Área não vegetada	Área vegetada	Corpo hídrico	Infraestrutura urbana
Acurácia	0,9788	0,9996	1,0000	0,9784
Precisão	0,9719	1,0000	1,0000	0,9426
Correlação	0,9441	0,9989	1,0000	0,9443
Taxa de erro	0,0212	0,0004	0,0000	0,0216
Verdadeiro Positivo	1.178,0	1.248,0	1.250,0	1.216,0
Falso Positivo	34,0	0,0	0,0	74,0
Verdadeiro Negativo	3.716,0	3.750,0	3.750,0	3.676,0
Falso Negativo	72,0	2,0	0,0	34,0

Porcentagem de previsões corretas, usando o conjunto de dados de teste	97,84%
Total de amostras de teste	10.000
RMSE	0,44

Fonte: O autor (2021).

Tabela 11 – Validador das Amostras para a classificação gerada a partir dos dados de radar.

	Área não vegetada	Área vegetada	Corpo hídrico	Infraestrutura urbana
Acurácia	0,9778	0,9822	0,9746	0,9766
Precisão	0,9560	0,9574	0,9584	0,9507
Correlação	0,9421	0,9536	0,9336	0,9392
Taxa de erro	0,0222	0,0178	0,0254	0,0234
Verdadeiro Positivo	1.194,0	1.215,0	1.174,0	1.195,0
Falso Positivo	55,0	54,0	51,0	62,0
Verdadeiro Negativo	3.695,0	3.696,0	3.699,0	3.688,0
Falso Negativo	56,0	35,0	76,0	55,0

Porcentagem de previsões corretas, usando o conjunto de dados de teste	95,56%
Total de amostras de teste	10.000
RMSE	0,41

Fonte: O autor (2021).

A partir das tabelas com os valores das métricas do Validador das Amostras é possível perceber que ambos os conjuntos de amostras e dados de treinamento foram bem classificados, pois apresentaram uma porcentagem de previsões corretas de mais de 95%.

Outra forma de avaliar os dados de treinamento é através das métricas que se referem à distribuição estatística dos pixels de treinamento por classe. Para todas as classes da ambas as classificações, os maiores valores apresentados correspondem às quantidades de verdadeiros positivos e verdadeiros negativos. Isto quer dizer que a maioria dos pixels das classes foram atribuídos de forma confiável e que apenas alguns pixels das classes foram perdidos na previsão.

4.4.2 Avaliação do desempenho das classificações

As Tabelas 12 e 13 exibidas a seguir apresentam as matrizes de confusão e índice Kappa das pós-classificações supervisionadas geradas a partir das imagens MSI/Sentinel-2 e C-SAR/Sentinel-1, respectivamente.

Tabela 12 – Matriz de Confusão e índice Kappa da classificação gerada a partir dos dados óticos.

	Área não vegetada	Área vegetada	Corpo hídrico	Infraestrutura urbana	Total
Área não vegetada	4870	0	179	244	5293
Área vegetada	608	11420	11	37	12076
Corpo hídrico	0	13	12827	0	12840
Infraestrutura urbana	1116	110	3	20980	22209
Total	6594	11543	13020	21261	52418
AP (%)	73,85	98,93	98,52	98,68	
AU (%)	92,01	94,57	99,90	94,47	
Índice Kappa	0,91	0,93	1,00	0,92	

Acurácia Global (%)	96,48
Índice Kappa da classificação	0,95

Fonte: O autor (2021).

Tabela 13 – Matriz de Confusão e índice Kappa da classificação gerada a partir dos dados de radar.

	Área não vegetada	Área vegetada	Corpo hídrico	Infraestrutura urbana	Total
Área não vegetada	5790	53	620	190	6653
Área vegetada	200	8784	0	3597	12581
Corpo hídrico	370	13	12390	22	12795
Infraestrutura urbana	234	2695	17	17437	20383
Total	6594	11545	13027	21246	52412
AP (%)	87,81	76,08	95,11	82,07	
AU (%)	87,03	69,82	96,83	85,55	
Índice Kappa	0,85	0,62	0,95	0,79	

Acurácia Global (%)	86,32
Índice Kappa da classificação	0,81

Fonte: O autor (2021).

A acurácia global da classificação supervisionada a partir dos dados óticos MSI/Sentinel-2 mostrou um valor de 96,48%, enquanto da classificação supervisionada a partir dos dados de radar C-SAR/Sentinel-1 revelou um valor de 86,32%. Ambas apresentaram um valor superior a 85% sendo consideradas satisfatórias de acordo com o limiar indicado por Anderson *et al.* (1976).

Pode ser observado que o índice Kappa para a classificação a partir dos dados óticos expressou o valor de 0,95, e para a classificação a partir dos dados de radar o índice Kappa apresentou o valor de 0,81, o que evidencia que ambas apresentaram um desempenho quase perfeito e/ou excelente de classificação conforme a Tabela 5 de desempenho a partir do coeficiente Kappa.

Conforme Rosot (2001), as acurácias mais informativas são as do produtor e do usuário pois elas envolvem todos os valores relacionados na matriz de erros. Realizando uma análise detalhada da Tabela 13 dos dados de radar, no contexto do produtor pode-se concluir que:

- Existe uma probabilidade de 87,81% dos pixels de referência da classe de área não vegetada terem sido classificados corretamente e uma probabilidade de 12,19% dos pixels terem sido erroneamente classificados como área vegetada (3,03%), corpo hídrico (5,61%) e infraestrutura urbana (3,55%);
- Existe uma probabilidade de 76,08% dos pixels de referência da classe de área vegetada terem sido classificados corretamente e uma probabilidade de 23,92% dos pixels terem sido erroneamente classificados como área não vegetada (0,46%), corpo hídrico (0,11%) e infraestrutura urbana (23,34%);
- Existe uma probabilidade de 95,11% dos pixels de referência da classe de corpo hídrico terem sido classificados corretamente e uma probabilidade de 4,89% dos pixels terem sido erroneamente classificados como área não vegetada (4,76%) e infraestrutura urbana (0,13%);
- Existe uma probabilidade de 82,07% dos pixels de referência da classe de infraestrutura urbana terem sido classificados corretamente e uma probabilidade de 17,93% dos pixels terem sido erroneamente classificados como área não vegetada (0,89%), área vegetada (16,93%) e corpo hídrico (0,10%).


No contexto do usuário pode-se concluir que:

- Existe uma probabilidade de 87,03% dos pixels classificados como área não vegetada representarem de fato esta classe no terreno, sendo os pixels restantes pertencentes às classes de área vegetada (0,80%), corpo hídrico (9,32%) e infraestrutura urbana (2,86%).
- Existe uma probabilidade de 69,82% dos pixels classificados como área vegetada representarem de fato esta classe no terreno, sendo os pixels restantes pertencentes às classes de área não vegetada (1,59%) e infraestrutura urbana (28,59%).
- Existe uma probabilidade de 96,83% dos pixels classificados como corpo hídrico representarem de fato esta classe no terreno, sendo os pixels restantes pertencentes às classes de área não vegetada (2,89%), área vegetada (0,10%) e infraestrutura urbana (0,17%).
- Existe uma probabilidade de 85,55% dos pixels classificados como infraestrutura urbana representarem de fato esta classe no terreno, sendo os pixels restantes pertencentes às classes de área não vegetada (1,15%), área vegetada (13,22%) e corpo hídrico (0,08%).

4.5 ANÁLISE VISUAL


Com o propósito de melhorar a avaliação da classificação produzida a partir das imagens de radar por meio de uma análise visual, as classes geradas através da pós-classificação foram vetorizadas e representadas separadamente como pode ser visto no lado direito das Figuras 19 a 22 expostas adiante.

Figura 19 – Representação da classe temática Área não vegetada.




Fonte: O autor (2021).

Figura 20 – Representação da classe temática Área vegetada.




Fonte: O autor (2021).

Figura 21 – Representação da classe temática Corpo hídrico.



Fonte: O autor (2021).

Figura 22 – Representação da classe temática Infraestrutura urbana.



Fonte: O autor (2021).


5 CONCLUSÕES E RECOMENDAÇÕES

Diante dos resultados apresentados neste trabalho pode-se concluir que a metodologia conseguiu satisfazer o objetivo proposto, isto é, as imagens de radar do sensor C-SAR/Sentinel-1 do tipo *Ground Range Detected* podem ser utilizadas como uma base de dados para a produção de uma classificação supervisionada satisfatória de uma região costeira que apresenta uma alta presença de nuvens. Este trabalho se mostra relevante dada a relativa escassez de estudos sobre esse tipo de produto na produção de uma classificação supervisionada, demonstrando que a metodologia discutida pode ser incorporada às metodologias com finalidades semelhantes.


Apesar de não exibir o mesmo desempenho da classificação supervisionada gerada a partir dos dados óticos do sensor MSI/Sentinel-2, a classificação a partir de dados de radar teve seu bom desempenho comprovado a partir das medidas das acurácias geral, do usuário e do produtor e também a partir do valor do índice Kappa. Estes resultados de avaliação foram próximo aos resultados obtidos utilizando dados óticos.

A classificação a partir dos dados de radar apresentou um certo grau de confusão entre as classes de Área vegetada e Infraestrutura urbana. Isto deve-se provavelmente ao fato de ambas as classes mostrarem algumas características semelhantes como a rugosidade superficial (dependendo do porte da vegetação e altura das construções) e orientação das feições, além de existirem áreas de diferentes dimensões com algum tipo de cobertura vegetal localizadas dentro dos centros urbanos. Os dados do Modelo Digital de Elevação (MDE) não foram incorporados aos dados de entrada da classificação pois quando feito isto, o resultado se tornava insatisfatório apresentando uma grande quantidade de erros.

Recomenda-se realizar um estudo minucioso acerca da interação dos pulsos de micro-ondas do radar com as características dos distintos alvos existentes na superfície em diferentes condições, e suas respectivas respostas, isto é, a análise dos valores de retroespalhamento. Com isto seria levado em consideração e avaliada a possibilidade da criação de uma biblioteca de dados espectrais a modo de facilitar e agilizar futuros trabalhos de classificação e mapeamento para que a qualidade da classificação com dados de radar seja ampliada e para que cada vez menos seja necessária a utilização de outras fontes de dados como os dados óticos. Este estudo apresenta uma grande importância devido à problemática exposta neste trabalho, que é referente ao empecilho que a presença de nuvens revela quando se utilizam dados óticos, mas que pode ser solucionado quando se utilizam dados de radar.

APÊNDICE A – REPRESENTAÇÃO DO MODELO DIGITAL DE ELEVAÇÃO

Fonte: O autor (2021).


APÊNDICE B – POLARIZAÇÕES COM REALCE DE CONTRASTE. A - VH; B - VV

Fonte: O autor (2021).

APÊNDICE C – FOTOS E COORDENADAS UTM (FUSO 25) DOS PONTOS COLETADOS EM CAMPO


PONTO 1 E: 288634,263; N: 9095411,592			
			
PONTO 2 E: 288463,672; N: 9093438,143			
			
PONTO 3 E: 288513,802; N: 9092173,683			
			
PONTO 4 E: 287348,695; N: 9090392,707			
			
PONTO 5 E: 287164,920; N: 9090795,569			
			
PONTO 6 E: 285332,003; N: 9091148,039			
			
PONTO 7 E: 283699,342; N: 9092231,501			
			

Fonte: O autor (2021).

APÊNDICE D – ÍNDICES POR DIFERENÇA NORMALIZADA

Fonte: O autor (2021).

APÊNDICE E – POLÍGONOS DAS AMOSTRAS DE REFERÊNCIA



Fonte: O autor (2021).

REFERÊNCIAS

ALBUQUERQUE, E. M. de; DINIZ, J. M. T.; LIMA, R. F. de; FERREIRA, F. N.; CHAGA SILVA, F. Das. 2015. Técnicas de geoprocessamento no suporte à análise da seca na microbacia do açude Jatobá II. **Revista Verde** (Pombal-PB, Brasil) 4, 27-33.

ANDERSON, J. R; HARDY, E. L.; ROACH, I. T.; WITMER, R. E. A land use and land cover classification for use with remote sensor data. **U.S. Geological Survey Professional Paper 964**. Washington, DC: U.S. Government Printing Office, 1976. 28 p.

ANTUNES, A. F. B. **Fundamentos de sensoriamento remoto em ambiente de geoprocessamento**. Centro Integrado de Estudos em Geoprocessamento. Curitiba: UFPR, 2002. 52 p.

APAC. Ortofotos e MDE do ano de 2016, provenientes do Projeto Pernambuco Tridimensional (PE3D). Recife, 2021.

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855-3862, 2001.

ATWOOD, D. K. et al. (2012) Improving PolSAR Land Cover Classification With Radiometric Correction of the Coherency Matrix. **IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing**, Vol. 5, N° 3, pp. 848-856.

AVERY, T. E.; BERLIN, G L. **Fundamentals of Remote Sensing and Airphoto Interpretation**. 5. ed. Upper Saddle River: Prentice Hall, 1992. 472 p.

AYTEKIN, O.; KOC, M.; ULUSOY, I. Local primitive pattern for the classification of SAR images. **IEEE Transactions on Geoscience and Remote Sensing**.v.51, p.2431–2441. 2013.

BARBOSA, F. L. R. et al. Classificação do uso e cobertura da terra utilizando imagens SAR/Sentinel 1 no Distrito Federal, Brasil. **Soc. nat.**, Uberlândia, v. 33, e55954, 2021. Epub Mar 01, 2021.

BELGIU, M.; DRAGUT, L. Random Forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.114, p. 24-31, 2016.

BRAUN, A. **Sentinel-1 Toolbox - SAR-based landcover classification with Sentinel-1 GRD products**. 2020. Disponível em <<https://step.esa.int/main/doc/tutorials/>>. Acesso em 2021.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

CALIXTO, D. D. et al., Análise Comparativa em Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento do Uso e Cobertura da Terra. **IV Simpósio Brasileiro de Geomática – SBG2017**. Presidente Prudente – SP, 2017. p. 180-185.

CAMPBELL, J. B. **Introduction to Remote Sensing**. 2nd. Ed. New York: The Guilford Press, 1996. 622 p.

CANDEIAS, A. L. B. et al. Comparativo do índice de vegetação de diferença normalizada (ndvi) entre os sensores oli - satélite LANDSAT-8 e MSI – satélite sentinel-2 em região semiárida. **Anuário do Instituto de Geociências**, Vol. 41 - 3 / 2018 p. 167-177, 2019.

CANDEIAS, A. L. B. et al. Estudo da extração de bordas de reservatório utilizando múltiplas técnicas de fusão de imagens. **Journal of Hyperspectral Remote Sensing**, v. 8, n. 3, p. 95-105, 2018.

CANDEIAS, A. L. B.; JUNIOR, J. R. T.; TEIXEIRA, A. M. A. Comparação dos índices de vegetação para imagens TM/Landsat 5, com correção e sem correção atmosférica. **R. bras. Geom.**, Curitiba, v. 5, n. 4, p. 524-542, out/dez. 2017.

CANDEIAS, A. L. B. et al. Análise espacial do reservatório de Itaparica dos anos 1978 e 2014. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE, p. 5718-5725.

CATALÃO, J. (2013) **Apontamentos de Princípios e Aplicações de Detecção Remota**. Texto não publicado, Departamento de Engenharia Geográfica, Geofísica e Energia da Faculdade de Ciências da Universidade de Lisboa, Lisboa.

CODE SECTOR. **Maverick: GPS Navigation**. Versão 2.8. Disponível em <<https://play.google.com/store/apps/details?id=com.codesector.maverick.lite>>. Acesso em 2021.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 136 p.

CPRM. **Atlas do meio físico do município de Jaboatão dos Guararapes – Estado de Pernambuco**. Superintendência Regional do Recife. Recife, 1997.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: [s.n.], 1992. 170 p.

DINIZ, J. M. F. S. **Avaliação do Potencial dos Dados Polarimétricos Sentinel-1a para Mapeamento do Uso e Cobertura da Terra na Região de Ariquemes – RO**. Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto. INPE, são José dos campos. 2019.

ENGELBRECHT, J. et al. A simple normalized difference approach to burnt area mapping using multi-polarisation C-band SAR. **Remote Sensing**, v.9, p.764, 2017.

ERDAS. **Erdas Field Guide**. Manual ERDAS Imagine 8.3. 4. ed. USA: 1997.

ESA. 2021. Página oficial da Agência Espacial Europeia (ESA) contendo informações dos satélites das missões Sentinel. Disponível em <<https://sentinels.copernicus.eu/web/sentinel/home>>. Acesso em 2021.

ESA. **SNAP Desktop**. Versão 8.0.0. Disponível em <<https://step.esa.int/main/download/snap-download/>>. Acesso em 2021.

FENG, J.; JIAO, L.; ZHANG, X.; YANG, D.: Bag-of-Visual-Words Based on Clonal Selection Algorithm for SAR Image Classification. **IEEE Geoscience and Remote Sensing Letters**. 2011.

FERREIRA, G. H. S. **Identificação de Áreas Inundáveis na porção Sul de Roraima com Auxílio de Imagens de Radar**. Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia. 2018.

FERREIRA, J. M. S.; FERREIRA, P. S.; MORAIS, Y. C. B.; GOMES, V. P.; FRANÇA, L. M. A.; GALVÍNCIO, J. D. 2013. Uso de técnicas de sensoriamento remoto na detecção de mudanças espaço-temporais das áreas de vegetação de mangue em Pernambuco. **Revista Brasileira de Geografia Física** 06, 356- 372.

FLEISS, J. L., LEVIN, B. and PAIK, M. C., 2013. **Statistical Methods for Rates and Proportions**. Third edition, John Wiley & Sons.

FONSECA, A.D.; FERNANDES, J. C. (2004) **Detecção Remota**. Lidel, Lisboa, Portugal.

FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. **Remote Sensing of Environment**, v. 239, n. January, p. 111630, 2020.

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

FUNG, A. K.; ULABY, F. T. **Matter-energy interaction in the microwave region**. Manual of Remote Sensing – Volume I. Second Edition. American Society of Photogrammetry, p.115-164. USA: 1983.

GOOGLE. **Google Earth Pro**. Versão 7.3.4. Disponível em < <https://www.google.com.br/earth/download/gep/agree.html>>. Acesso em 2020.

HENDERSON, F. M.; LEWIS, A. J. Radar detection of wetland ecosystems: a review. **International Journal of Remote Sensing**. v. 29, N. 20, p.5809–5835, 2008.

HENDERSON, F. M.; LEWIS, A. J. **Principles and applications of imaging radar, manual of remote sensing**. 3. ed. New York: John Wiley & Sons, 1998. 866 p.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente – Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese Editora, 598 p. 2009.

JIN, H.; MOUNTRAKIS, G.; STEHMAN, S. V. (2014). “Assessing integration of intensity, polarimetric scattering, interferometric coherence and spatial texture metrics in PALSAR-derived land cover classification.” **ISPRS Journal of Photogrammetry and Remote Sensing**, Vol. 98, Págs. 70-84.

KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. 1928. Wall-map 150cmx200cm.

LANDGREBE, D. A., The quantitative approach: concept and rationale. In: Swain, P. H.; Davis, S.M. **Remote sensing: the quantitative approach**. New York, McGraw-Hill, 1978. 396p.

LANDIS, J. R. e G.G. KOCH. 1977. The measurement of observer agreement for categorical data. **Biometrics**, Vol. 33, N° 1, pp. 159-174.

LANG, M. W.; TOWNSEND, P.A.; KASISCHKE, E. S. 2008. Influence of incidence angle on detecting flooded forests using C-HH synthetic aperture radar data. **IEEE Transactions on Geoscience and Remote Sensing**, 46(2):535-546.

LANG, M.W.; KASISCHKE, E. S. 2008. Using C-band synthetic aperture radar data to monitor forested wetland hydrology in Maryland's coastal plain, USA. **Remote Sensing of Environment**, 112: 3898-3907.

LEE, J.; POTTIER, E. **Polarimetric radar imaging from basics to applications**. New York: CRC Press, 2009. 398 p.

LEWIS, A. J.; HENDERSON, F. M. 1998. Radar fundamentals: The Geoscience Perspective. In: F.M. HENDERSON& A.J. LEWIS (eds.). **Principles & Applications of Imaging Radar: manual of remote sensing**. 3rd ed., 2, John Wiley, New York, p.: 131 - 181.

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

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 3 rd. Edit. Crawfordsville: John Wiley and Sons, 1994, 750 p.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, p. 823-870, 2007.

MAPBIOMAS. Disponível em <<https://mapbiomas.org/>>. Acesso em 2021.

MATHER, P.; TSO, B. **Classification methods for remotely sensed data**. Boca Raton: CRC press, 2009.

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

MATSUKUMA, C. K. **Análise comparativa de algoritmos de classificação não-supervisionada, no mapeamento do uso e cobertura da terra**. 2002. 84 p. Dissertação (Mestrado) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba. 2002.

MENESES, P. R.; ALMEIDA, T. de (Orgs). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, 2012.

MONSERUD, R. A. and LEEMANS, R., 1992. Comparing global vegetation maps with the Kappa statistic. **Ecological Modelling**, 62(4), 275-293.

MOREIRA, A. et al., (2013) “A tutorial on Synthetic Aperture Radar” **IEEE Geoscience and Remote Sensing Magazine**, Vol.1, Nº 1, pp. 6-43.

NOBREGA, R. S.; FARIAS, R. F. de L. Eventos Extremos Pluviais em Jaboatão dos Guararapes: Climatologia e Estudo de Caso. **Revista do Departamento de Geografia**. Universidade de São Paulo, 2016.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4ª Edição-São Paulo, Blucher, 363p. 2010.

NOVO, E. M. L. de M. Fundamentos e Aplicações de Radar no Estudo de Áreas Alagáveis. IN: DE SOUZA, R. B. (Ed.). **Oceanografia por satélites**. Oficina de Textos. 2009.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 2ª edição. São Paulo: Edgard Blücher, 1995. 308 p.

OLIVEIRA, C. B. de S.; CANDEIAS, A. L. B.; JUNIOR, J. R. T. Utilização de índices físicos a partir de imagens OLI – TIRS para o mapeamento de uso e cobertura da terra no entorno do aeroporto internacional do Recife/Guararapes – Gilberto Freire. **Revista Brasileira de Geografia Física** v.12, n.03 (2019) 1039-1053.

OSGEO. **QGIS Desktop**. Versão 3.10.14. Disponível em <https://www.qgis.org/pt_BR/site/forusers/download.html>. Acesso em 2020.

PAL, M. Random Forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, p. 217-222, 2005.

PARADELLA, W. R. 1996. **Imageamento por Radar: Princípios e Aplicações Gerais**. Apostila do curso “Sensoriamento remoto com radar em aplicações geoambientais”.

PERROCA, M. G.; GAIDZINSKI, R. R. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes: coeficiente Kappa. **Revista da Escola Enfermagem da USP**, v. 37, n. 1, p. 72-80, 2003.

PINHEIRO, C.; LARANJEIRA, M. 2013. Análise do ambiente térmico e das condições de ventilação para a definição das funções climáticas na área urbana de Guimarães. **Revista de Geografia e Ordenamento do Território (GOT)**. 249-272.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São Paulo, Oficina de Textos. 2ª ed. 2015.

QUARTAROLI, C. F.; VICENTE, L. E.; ARAÚJO, L. S. de. Sensoriamento Remoto. In: TÔSTO, S. G.; RODRIGUES, C. A. G.; BOLFE, E. L.; BATISTELLA, M. (Ed.). **Geotecnologias e geoinformação**. Brasília, DF: Embrapa, 2014.

RANEY, K. 1998. Radar Fundamentals: technical perspective. In: F.M. HENDERSON& A.J. LEWIS (eds.). **Principles & Applications of Imaging Radar: manual of remote sensing**. 3rd ed., .2, John Willey, New York, p.: 8 - 130.

- REZENDE, P. S.; MARQUES, D. V.; ROSA, R. Uso de dados do Sentinel-2 para cálculo de NDVI com base nos valores da refletância aparente e de superfície. **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**. INPE Santos - SP, 2017.
- RICHARDS, J.A. **Remote sensing digital images analysis: an introduction**. Berlin: Springer-Verlag, 1986. 281 p.
- RICHTER, R. A spatially adaptive fast atmospheric correction algorithm. **International Journal of Remote Sensing**, v. 17, n. 6, p. 1201-1214, 1996.
- ROSOT, N. C. **Integração de Imagens de Sensores de Microondas e Ópticos para fins de Mapeamento e Classificação de Reflorestamentos no Sul do Brasil**. Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina. Florianópolis, 2001.
- ROUGHGARDEN, J.; RUNNING, S.W.; MATSON, P.A. What does remote sensing do for Ecology? **Ecology**, v. 72, n.6, p.1918-1922, 1991.
- SABINS, F. F. 1997. **Remote sensing: principles and interpretation**. W.H. Freeman and Company, 3d Ed, San Francisco, 494 pp.
- SARAIVA, C. F. A. **Avaliação do Potencial das Imagens Sentinel-1 para Identificação de Culturas Agrícolas**. 2015. Dissertação (Mestrado em Engenharia Geográfica) – Departamento de Engenharia Geográfica, Geofísica e Energia, Universidade de Lisboa, Portugal, 2015.
- SCHOWENGERDT, R. A. Remote sensing: model and methods for image processing. London: **Academic Press Inc**, 1997. 522 p.
- SERVELLO, E. L.; SANO, E. E.; PANTOJA, N. V. Sentinel-1 SAR: efeito de filtros espaciais no estudo do uso do solo amazônico. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, INPE, 25 a 29 de abril de 2015.
- SILVA, A. G. P. et al. Integração de Imagens Orbitais Ópticas e SAR com Processamento em Nuvem no Mapeamento da Cobertura da Terra No Cerrado. **Revista Geoaraguaia**, v.11 n. Esp. Geotecnologias. p. 85 - 106. Barra do Garças – MT, 2021.
- SILVA, M. A. O. da; LIPORACE, F. S. Detecção Automática de Nuvem e Sombra de Nuvem em Imagens de Sensoriamento Remoto. **BCG - Boletim de Ciências Geodésicas**. Curitiba, v. 22, no2, p.369- 388, 2016.
- SPRING – Sistema de processamento de informações georreferenciadas. São José dos Campos: NETGIS, 1998 (a). v. 2: Processamento de imagens.
- TEIXEIRA, A. M. A. **Método de atualização nas escalas 1:100000 e 1:250000 do mapeamento sistemático a partir de imagem de sensoriamento remoto: reservatório de Itaparica**. Dissertação de Mestrado em Ciências Geodésicas e tecnologias da Geoinformação, Universidade Federal de Pernambuco, 2016.

TEIXEIRA, S. G. **Radar de Abertura Sintética aplicado ao Mapeamento e Reconhecimento de Zonas Úmidas Costeiras**. Tese (doutorado em geologia) – Universidade Federal do Pará, Instituto de Geociências, Programa de Pós-Graduação em Geologia e Geoquímica, Belém, 2011.

ULABY, F. T.; MOORE, R. K.; FUNG, A. K. 1986. **Microwave remote sensing: active and passive**, Artech House, vol. II. Norwood, 360 pp.

VENTURIERI, A.; SANTOS, J.R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E.E. (Ed.) **Sistema de informações geográficas**. Aplicações na agricultura. 2. ed. Brasília: Embrapa – SPI / Embrapa – CPAC, 1998. p. 351 – 371.

WANG, Y.; HESS, L.L.; FOLOSO, S.; MELACK, J. M. 1995. Understanding the Radar Backscattering from flooded and nonflooded amazonian forests: Results from canopy backscatter modeling. **Remote Sensing of Environment**, 54: 324–332.

WARING, R. H. et al. Imaging radar for ecosystem studies. **Bio Science**, v.45(10), p.715-723. 1995.

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**; Taylor Francis: Boca Raton, FL, USA, 379p. 2006

ZYL, J. V.; KIM, Y. (2011) **Synthetic Aperture Radar Polarimetry**. John Wiley & Sons, Hoboken, NJ.