



ENZO MESSIAS CUSTODIO NIZA

**DETECÇÃO DE FALHAS EM PLANTIOS DE
EUCALIPTO UTILIZANDO DADOS SAR SENTINEL-**

1

LAVRAS-MG

2023

ENZO MESSIAS CUSTODIO NIZA

**DETECCÃO DE FALHAS EM PLANTIOS DE
EUCALIPTO UTILIZANDO DADOS SAR SENTINEL-1**

Trabalho de conclusão de curso apresentado à
Universidade Federal de Lavras, como parte das
exigências do Curso de Engenharia Florestal,
para obtenção do título de Bacharel.

Prof. Dr. Fausto Weimar Acerbi Júnior
Orientador

Ma. Juliana Maria Ferreira de Souza Diniz
Coorientadora

LAVRAS-MG

2023

AGRADECIMENTOS

Esta talvez seja a parte mais difícil, foram tantas pessoas que passaram pelo meu caminho, algumas pra ficar, outras só por um tempo, algumas já nem estão mais aqui fisicamente, mas cada uma dessas pessoas contribuiu um pouquinho para que eu chegasse onde estou e para que eu me tornasse quem eu sou.

É impossível não começar agradecendo aos meus pais, Lúcia e Messias, que desde sempre vem fazendo o possível e o impossível pra me apoiar, me ver crescer e me ver feliz. À minha irmãzinha Maria Luiza, que eu admiro muito pela coragem, força e por estar sempre comigo e também a toda minha família, por sempre acreditar em mim.

À Tia Cida e ao Tio Laurenço, por me acolherem como filho e me darem todo o suporte que eu precisei nesses anos de faculdade, saibam que sem vocês isso não seria possível.

À Gabi, meu amor, por todo o apoio e companheirismo, por sempre acreditar no meu potencial e me fazer sentir a pessoa mais especial e amada do mundo!

Aos amigos do grupo “Asaian Bolt” por estarem comigo em todos os momentos, mesmo sem muitos de nós nunca termos nos vistos pessoalmente. Ao “Na Fronteira” pelas risadas, parcerias e tantas noites de squadterapia. Ao pessoal do “Rep MB” por me acolherem e me fazer parte da família, são tantas histórias, raxinhas, risadas, momentos incríveis e por não me deixarem enlouquecer na pandemia.

A todos os amigos que eu fiz na UFLA: galera da floresta, da entomologia, galera do CIMVEST, galera do UFLA RUNNERS, uma galera com amizades que duram até hoje e algumas amizades sinceras de 5 minutos na fila do mamute. Agradecimento especial ao Marco Tulio e a Brunão, obrigado amigos, vocês são uns amigos!

À Juliana Diniz, minha coorientadora e referência sobre Radar, por todo o conhecimento transmitido e ao meu orientador Fausto, um professor fantástico, que me converteu ao geoprocessamento e me abriu muitas portas.

À Suzano, por me proporcionar tamanho crescimento e realização profissional. Aos companheiros de trabalho, por todos os momentos e conhecimentos compartilhados. Em especial ao Richard e à Dani, meus gestores que sempre me apoiaram e confiaram em mim. Ao Mairon, que foi meu mentor, parceiro de fábrica e camisa 9 nas horas vagas. À Eve, por todo o apoio neste trabalho, pela parceria e por aceitar compor a minha banca.

“A vida é como uma caixa de chocolates, você nunca sabe o que vai encontrar.”

-Forrest Gump

RESUMO

Controlar a área de efetivo plantio é fundamental para que não falte madeira nas fábricas de celulose, com isso, a identificação das falhas de plantios (que podem ocorrer por vários motivos) é fundamental para não contabilizar madeira inexistente como potencial abastecimento e para tentar mitigar as causas da perda de área produtiva. É possível mapear falhas de plantios através de técnicas de sensoriamento remoto de forma rápida e precisa. Um fator limitante para os sensores ópticos é a cobertura de nuvens, que impede o mapeamento da superfície terrestre em vários períodos do ano, principalmente nas regiões tropicais. A utilização de dados SAR (Radares de Abertura Sintética) pode ser considerada como alternativa nesses monitoramentos, uma vez que não sofre influência da cobertura de nuvens. Assim, o objetivo principal deste trabalho foi avaliar o potencial do uso das imagens do sensor de radar a bordo do satélite Sentinel-1A para a detecção de falhas de plantios em uma fazenda produtora de eucalipto no município de Conceição da Barra-ES. Para isso, foram testados doze cenários de classificação que buscavam distinguir as classes de floresta plantada e falha de plantio a partir da combinação entre as seguintes variáveis: tipo de imagem (SLC e GRD), janela de filtragem do filtro Lee (3x3 e 9x9) e polarização (VH, VV e RC). A validação da classificação foi realizada a partir da interpretação visual de uma imagem SPOT6 de alta resolução espacial, onde foram gerados 2000 pontos de acurácia, que foram utilizados como base para comparar com os valores classificados em cada cenário e obtenção das matrizes de confusão, acurácia global e número Kappa. A partir da comparação dos cenários, foi constatado que o cenário G9VH, que utilizou a polarização VH da imagem GRD, com aplicação do filtro Lee com janela 9x9, apresentou o melhor desempenho classificatório, com acurácia global de 91,4% e número Kappa igual a 0,826, sendo conceituada como uma classificação “Excelente”. Por meio da comparação da classificação realizada no cenário G9VH do Sentinel-1A com o mapeamento realizado com NDVI do sensor óptico, observou-se um desempenho 3,15% melhor do sensor óptico. No geral, os dados de radar apresentaram valores de acurácia global e número Kappa satisfatórios e conseguiram distinguir muito bem entre as áreas de floresta plantada e falhas de plantio, além de terem a vantagem de não sofrerem influências das condições atmosféricas.

Palavras-chave: Monitoramento florestal. Sensoriamento Remoto. Radar de Abertura Sintética. Polarização.

ABSTRACT

Controlling the actual planting area is fundamental so that the pulp mills do not run out of wood. Therefore, the identification of planting failures (which can occur for several reasons) is fundamental so as not to count non-existent wood as a potential supply and to try to mitigate the causes of loss of productive area. It is possible to map planting failures through quickly and accurately remote sensing techniques. A limiting factor for optical sensors is cloud cover, which prevents mapping the Earth's surface at various times of the year, especially in tropical regions. The SAR (Synthetic Aperture Radar) data can be used as an alternative in these monitoring, since it is not influenced by cloud cover. According, the main goal of this work is to evaluate the potential of using images from the radar sensor on board of the Sentinel-1A satellite for the plantation detection of failures for eucalyptus producing areas in Conceição da Barra-ES. For this, twelve classification scenarios were tested that sought to distinguish the classes of planted forest and planting failure from the combination of the following variables: image type (SLC and GRD), Lee filter filtering window (3x3 and 9x9) and polarization (VH, VV and RC). The classification validation was carried out based on the visual interpretation of a SPOT6 image of high spatial resolution. Where 2000 accuracy points were generated, which were used as a basis for comparing with the classified values in each scenario and obtaining the confusion matrices, global accuracy and Kappa number. Comparing the scenarios, it was found that the G9VH scenario, which used the VH polarization of the GRD image, applying the Lee filter with a 9x9 window, presented the best classification performance. Presenting a global accuracy of 91.4% and a Kappa number equal to 0.826, being conceptualized as an "Excellent" classification. Comparing the classification performed in the G9VH scenario of the Sentinel-1A with the mapping performed with the optical sensor's NDVI, a 3.15% better performance of the optical sensor was observed. In general, the radar data showed satisfactory values of global accuracy and Kappa number and were able to distinguish very well between areas of planted forest and planting failures, in addition to having the advantage of not being influenced by atmospheric conditions.

Keywords: Forest monitoring. Detection of planting failures. Synthetic Aperture Radar. Sentinel-1.

LISTA DE FIGURAS

Figura 2.1 - Fluxo de aprovação e validação das falhas\sinistros reportados.....	14
Figura 2.2 - Espectro eletromagnético e bandas da região de nmicro-ondas	16
Figura 2.3 - Onda eletromagnética com os dois componentes: campo elétrico (E) e campo magnético (M), ambas perpendiculares à direção de propagação.....	18
Figura 3.1 – Localização da área de estudo.....	24
Figura 3.2 - Fluxograma da metodologia geral desenvolvida.....	27
Figura 3.3 - Fluxograma das etapas de processamento das imagens.....	28
Figura 3.4 – Resultado da ferramenta <i>Split</i>	29
Figura 3.5 – Resultado da ferramenta <i>Deburst</i>	30
Figura 3.6 – Resultado da ferramenta <i>Multilooking</i> quatro looks.....	30
Figura 3.7 – Comparação do resultado do filtro Lee para as janelas 3x3 e 9x9.....	31
Figura 3.8 – Resultado da ferramenta <i>Range Doppler Terrain Correction</i> utilizando o MDE SRTM.....	31
Figura 3.9 – Exemplo de classificação pixel a pixel.....	34
Figura 3.10 – Elementos de um gráfico Box-plot.....	35
Figura 3.11 – Gráficos Box-plot obtidos para os cenários estudados.....	36
Figura 3.12 – Aplicação das ferramentas <i>Clip Raster</i> e <i>Reclassify</i> na imagem do cenário S3VH.....	38
Figura 3.13 – Obtenção das amostras de acurácia a partir do vetor de Unidade de Produção.....	39
Figura 3.14 – Obtenção da tabela comparativa entre pontos classificados x pontos de acurácia.....	39
Figura 4.1 – Gráfico comparativo com valores de Acurácia Global (AG), Acurácia do Produtor (AP) e Acurácia do Usuário (AU)	43

Figura 4.2 – Gráfico comparativo entre os valores de Acurácia Global (AG) das imagens SLC e GRD.....	43
Figura 4.3 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das imagens SLC e GRD.....	44
Figura 4.4 – Gráfico comparativo entre os valores de Acurácia Global (AG) das janelas 3x3 e 9x9 do Filtro Lee.....	45
Figura 4.5 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das janelas 3x3 e 9x9 do Filtro Lee.....	45
Figura 4.6 – Gráfico comparativo entre os valores de Acurácia Global (AG) das polarizações VH, VV e RC.....	46
Figura 4.7 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das polarizações VH, VV e RC.....	47
Figura 4.8 – Classificação do cenário G9VH e pontos de validação.....	49
Figura 4.9 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe e tipo de sensor.....	50
Figura 4.10 – Comparação das classificações realizadas pelo cenário G9RD do radar, NDVI do sensor óptico e mapa com as diferenças entre as classificações.....	51

LISTA DE TABELAS

Tabela 2.1- Agrupamento qualitativo do coeficiente kappa.....	23
Tabela 3.1 - Características das bandas espectrais do sensor SPOT6.....	26
Tabela 3.2 - Características das bandas espectrais do sensor Sentinel-2.....	26
Tabela 3.3 – Valores de corte e premissas de classificação para os diferentes cenários estudados.....	37
Tabela 4.1 – Acurácia Global, Kappa e desempenho para todos os cenários avaliados.....	42
Tabela 4.2 – Matriz de confusão referente ao cenário G9VH.....	48
Tabela 4.3 – Matriz de confusão referente a classificação com o NDVI do Sentinel-2A.....	49
Tabela 4.4 – Comparação de desempenho classificatório entre os sensores radar e óptico.....	50

SUMÁRIO

1. INTRODUÇÃO	10
2. FUNDAMENTAÇÃO TEÓRICA	11
2.1. As florestas plantadas e a importância do inventário florestal	11
2.2. Índice de Vegetação por Diferença Normalizada	12
2.3. Monitora	13
2.4. Influência das nuvens	15
2.5. Radares de Abertura Sintética – SAR	15
2.6. Ruído Speckle e filtros adaptativos	16
2.7. Polarizações	17
2.8. Mecanismos de espalhamento	19
2.9. Coeficiente de retroespalhamento	19
2.10. Sentinel-1	20
2.11. Classificação da imagem	22
2.12. Validação do desempenho da classificação	22
3. MATERIAL E MÉTODOS	24
3.1. Área de estudo	24
3.2. Aquisição dos dados SAR	25
3.3. Dados auxiliares	25
3.4. Metodologia Aplicada	27
3.5. Processamento dos dados SAR	28
3.5.1. Dados SLC	29
3.5.2. Dados GRD	32
3.6. Processamento dos dados ópticos	32
3.6.1. Dados SPOT6	32
3.6.2. Dados Sentinel-2A	33
3.7. Classificação dos dados SAR	33
3.7.1. Método de classificação	33
3.7.2. Definição dos valores delimitadores de classes	34
3.7.3. Classificação	37
3.8. Validação da classificação	38
3.8.1. Amostras de acurácia	38
3.8.2. Matriz de confusão	39
3.9. Comparação com o sensor óptico	40
4. RESULTADOS	40

4.1.	Análise exploratória dos coeficientes de retroespalhamento	40
4.2.	Resultado da classificação	41
4.3.	SLC x GRD	43
4.4.	Filtro Lee 3x3 x Filtro Lee 9x9	44
4.5.	Polarizações VH x VV x RC	46
4.6.	Cenário com melhor desempenho	47
4.7.	Radar x óptico	49
5.	DISCUSSÃO DOS RESULTADOS	51
5.1.	Classificação com coeficiente de retroespalhamento do radar	51
5.2.	Comparação entre radar e óptico	53
6.	CONCLUSÕES E CONSIDERAÇÕES FINAIS	54

1. INTRODUÇÃO

Garantir o abastecimento de madeira das unidades industriais é um desafio muito grande. No ano de 2020 o consumo de madeira oriunda de árvores plantadas para uso industrial atingiu a marca de 216,6 milhões de metros cúbicos, dos quais, 161,3 milhões se referem ao consumo da madeira de eucalipto. No mesmo ano, a área total de árvores plantadas totalizou 9,55 milhões de hectares, sendo o cultivo do eucalipto responsável por 78% dessa área, totalizando 7,47 milhões de hectares com uma produtividade média de 36,8 metros cúbicos por hectare (IBÁ, 2021).

Várias mudanças podem acontecer ao longo do ciclo da floresta, podendo ser causadas tanto por processos antrópicos quanto por processos naturais (JOSHI et al., 2016). Alguns eventos como incêndios, ocupações, incidência de pragas e doenças, déficit hídrico, furto de madeira, dentre outros, podem provocar uma diminuição da área líquida do plantio. Essa redução de área implica na diminuição do volume de madeira disponível no talhão afetado, resultando na necessidade de readequações no planejamento florestal do início ao fim, desde aumentar áreas de novos plantios para compensar a área perdida, repensar a programação da colheita e até cogitar buscar madeira de terceiros para conseguir suprir a demanda de madeira.

Os sensores ópticos são amplamente utilizados na classificação da cobertura do solo e na detecção de falhas de plantios principalmente com o uso de índices de vegetação, que são obtidos a partir de operações matemáticas com os valores de reflectância das diferentes bandas espectrais dos sensores. Dentre os índices, vale destacar o NDVI (Índice de Vegetação por Diferença Normalizada), que é calculado a partir da diferença entre as reflectâncias das bandas do infravermelho próximo (NIR) e do vermelho (ROUSE et al., 1973). O grande problema encontrado na utilização dos sensores ópticos é a dificuldade de encontrar imagens com baixo percentual de cobertura de nuvens durante os períodos chuvosos do ano, muitas vezes ficando vários meses sem conseguir imagens de determinadas áreas.

Os radares são sensores ativos que possuem sua própria fonte de radiação eletromagnética e operam na faixa do espectro eletromagnético denominada de micro-ondas, sendo pouco influenciados pela cobertura de nuvens e por demais constituintes atmosféricos. Por isso, os dados SAR (Radar de Abertura Sintética) têm se apresentado como uma alternativa para o monitoramento e mapeamento de áreas em regiões tropicais (ASNER, 2001; ENGELBRECHT et al., 2017; HENDERSON; LEWS, 1998). Além disso, os dados SAR são sensíveis à biomassa e à estrutura florestal, o que possibilita uma diferenciação entre os diferentes tipos de cobertura do solo.

Dessa forma, o objetivo do atual trabalho é testar o potencial dos dados SAR na detecção de falhas nos plantios de eucalipto em uma fazenda no município de Conceição da Barra, ES. Já que essa região sofre grande influência da cobertura de nuvens durante o período chuvoso, dificultando a obtenção de imagens ópticas.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. As florestas plantadas e a importância do inventário florestal

As florestas plantadas são a principal alternativa ao uso da madeira na visão do desenvolvimento sustentável, uma vez que preservam as florestas naturais e usam as mesmas áreas em sua plantação durante vários ciclos e rotações (IBÁ, 2020). Atualmente, considera-se que o setor brasileiro de árvores plantadas é o mais produtivo do mundo. Em 2020, o Brasil apresentou uma produtividade média de 36,8 m³/ha ao ano nos plantios de eucalipto e, no mesmo ano, a área total de árvores plantadas totalizou 9,55 milhões de hectares cultivadas para fins industriais, representando uma queda de 1,44% em relação a 2019. Desse total, 78% são representadas por cultivo de eucalipto, com 7,47 milhões de hectares (IBÁ, 2020).

Nas empresas do setor florestal, o conhecimento do crescimento e da produção presente e futura de árvores e povoamentos florestais é fundamental para viabilizar o planejamento da atividade florestal (SCOLFORO, 1998), várias decisões são tomadas baseadas no volume de madeira necessário para suprir a demanda das unidades industriais ao longo do tempo, garantindo que não falte matéria prima para o seu funcionamento. Segundo Péllico Netto e Brena (1997), o inventário florestal é uma atividade que visa obter informações qualitativas e quantitativas dos recursos florestais existentes em uma área pré-especificada. Por exemplo, em plantios florestais com fins madeireiros, o inventário florestal visa principalmente a estimativa de variáveis como peso, área basal, volume, qualidade do fuste, estado fitossanitário, classe de copa e potencial de crescimento da espécie florestal (LOETSCH; HALLER, 1964; HARRY, 1971; FRAYER et al., 1974; FRAYER, 1979; SCHRENDER et al., 1993, apud MACEDO 2009).

Ao realizar o inventário de áreas muito grandes, como é o caso das grandes empresas do setor, se faz necessário a utilização de técnicas de amostragem que estimam o volume de algumas parcelas dentro do talhão para depois ser feita a extrapolação do volume para a área total do plantio, tendo em vista que a extensão da floresta inviabiliza a medição de todos os indivíduos da área inventariada. Couto (1984) reforça a importância da medida correta da área de plantio, já que as informações médias obtidas são por unidade de área, um mapeamento bem-feito com a determinação precisa da área é imprescindível para se obter um resultado confiável.

Visto que durante o ciclo de uma floresta, podem ocorrer falhas nos plantios em decorrência de eventos antrópicos como roubo de madeira, ocupações e incêndios criminais ou naturais como ataque de pragas e déficit hídrico, é imprescindível detectá-las já que a redução de área com floresta em pé, implica na diminuição do volume de madeira disponível na área.

2.2. Índice de Vegetação por Diferença Normalizada

Na segunda metade do século XX, período que acontecia a Guerra Fria, houve um grande desenvolvimento na área espacial, sendo lançados diversos satélites com câmeras embarcadas, marcando o início das fotografias orbitais (FLORENZANO, 2011). Algumas décadas se passaram e hoje, as câmeras embarcadas nos satélites são poderosos sensores multiespectrais, que são capazes de captar a energia eletromagnética refletida pela superfície terrestre em diversos comprimentos de onda, possibilitando o monitoramento de recursos naturais como a vegetação (ALLEN; RICHARDSON, 1968).

A reflectância da vegetação ao longo do espectro eletromagnético depende de fatores como a quantidade de biomassa, a composição físico-química e estrutura do dossel vegetal (PONZONI et al., 2012). Segundo Allen e Richardson (1968), a vegetação possui um padrão de reflectância da energia eletromagnética no comprimento de onda do vermelho e do infravermelho próximo. Isso se deve ao fato de a vegetação sadia absorver mais energia eletromagnética na faixa do vermelho devido aos pigmentos de clorofila, e refletir mais na faixa do infravermelho próximo devido à estrutura celular das plantas (JENSEN, 2009).

A utilização de técnicas de sensoriamento remoto com sensores ópticos tem sido muito utilizada na avaliação quantitativa da vegetação, principalmente por meio dos índices de vegetação. Segundo Tucker (1979), esses índices baseiam-se em razões elaboradas a partir de valores de reflectância ou radiância apresentados pela cobertura vegetal, nas regiões espectrais do visível e do infravermelho próximo, visto que estas regiões são fortes indicadores da quantidade de biomassa fotossinteticamente ativa.

Dentre os índices de vegetação mais usados destaca-se o NDVI (Normalized Difference Vegetation Index), que tem sido relacionado à fatores como: biomassa, índice de área foliar (IAF), produtividade primária e à radiação fotossintética (TEILLET et al., 1997). O NDVI foi proposto por Rouse et al (1973) e é calculado por meio da equação 1.

$$NDVI = \frac{IVP-V}{IVP+V} \quad (1)$$

Onde:

IVP = Reflectância na região espectral do infravermelho Próximo

V = Reflectância na região espectral do vermelho

De acordo com Epiphany et al. (1996), o NDVI tem a propriedade de variar entre -1 e + 1, sendo que quanto mais próximo de 1, maior tende a ser a densidade da vegetação. Já valores que tendem a zero representam a ausência de vegetação, tais como áreas de solo exposto. Com isso, a utilização do NDVI para a detecção de falhas ou danos nos plantios tem um desempenho muito bom, um estudo de Dassan et al. (2019) mostrou que mesmo utilizando cenas de satélites disponibilizados gratuitamente, e uma resolução espacial de 30 metros, foi possível desenvolver uma ferramenta para identificação de desfolha, possibilitando o monitoramento dos plantios de eucalipto.

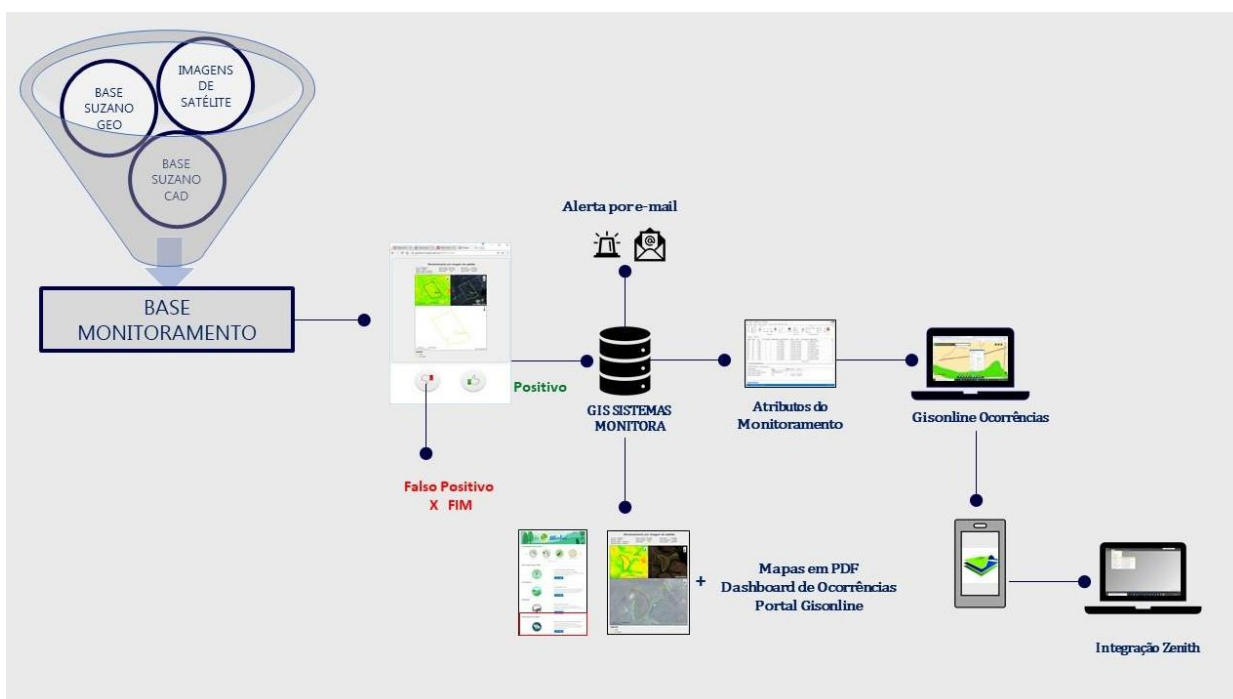
2.3. Monitora

Na Suzano S.A. existe uma metodologia de monitoramento de plantio em florestas adultas denominado “Monitora”, esse sistema automatizado busca diariamente por imagens ópticas (com percentual de cobertura de nuvens inferior a 50%, sendo esse número parametrizável) que englobem as áreas de posse Suzano e que são disponibilizadas gratuitamente, tais como Landsat e Sentinel 2. Após serem baixadas, as imagens passam por uma segunda filtragem de nuvens, que são máscaras desenvolvidas para cada satélite, as áreas de intercessão de eucalipto que não cruzam com a máscara de nuvens seguem para os processamentos posteriores.

Para cada Unidade de Produção (UP) é então calculado o índice de vegetação por diferença normalizada - NDVI. Com o índice calculado, considera-se que dentro das UPs deveria ter floresta e é adotado um valor de corte em que os pixels com valor de NDVI superiores são considerados como eucalipto e os valores inferiores ao limite são considerados como área sinistrada, que são áreas que não apresentam um plantio homogêneo e saudável devido à ocorrências florestais como incêndio, roubo de madeira, praga, vendaval, dentre outros. O valor de corte é definido por satélite e é um número parametrizável, para Landsat usamos 0,25 e para Sentinel 0,33. Outro índice a ser considerado é a área mínima para se reportar um erro, sendo reportados apenas falhas de plantios com área superior a 0,015 ha.

Conforme mostra a figura 2.1, após indicar uma possível falha no plantio, o sistema retorna uma imagem png em sistema HTML para avaliação do time de geoprocessamento em uma plataforma chamada “Timber”, em que chegam várias imagens apontando áreas sinistradas e o avaliador analisa se há realmente problemas com aquela área ou se foi apenas um falso positivo provocado principalmente por nuvens, sendo essa a única etapa de interface manual do processo. Por fim, todas as imagens avaliadas como possível falha de plantio são disponibilizadas no Mobile da empresa para validação *in loco* e posterior tratativas em Cadastro Florestal.

Figura 2.1 - Fluxo de aprovação e validação das falhas\sinistros reportados.



Fonte: Suzano S.A.

A principal limitação dessa tecnologia são as condições atmosféricas, já que em regiões ou épocas com alta incidência de nuvens, o monitoramento é bastante comprometido, muitas vezes ficando meses sem conseguir imagens de certas áreas. Com isso, o monitoramento de muitas áreas de posse da Suzano, principalmente as localizadas nos estados do Espírito Santo, Bahia e Maranhão, fica altamente comprometido durante grande parte do ano, restando poucas cenas para o sistema do Monitora processar. Consequentemente, isso resulta em uma lacuna muito grande a partir do momento que a ocorrência acontece até o momento que é reportada, atrasando a atuação das equipes de campo que poderiam tomar medidas para mitigar ou minimizar os impactos do sinistro, resultando em uma maior perda de área de plantio. Outro problema é que as nuvens e sombras de nuvem que não são filtradas pela máscara de nuvem

são apontadas como falso positivo, resultando em um alto número de alertas que a equipe responsável pela avaliação no Timber deve descartar.

2.4. Influência das nuvens

Apesar de as imagens dos sensores ópticos serem de mais fácil interpretação e possuírem diversas técnicas de processamento de imagens que facilitem esse processo, elas são extremamente vulneráveis à visibilidade atmosférica (BENEDITTI, 2010).

Segundo Loebmann et al. (2015), as nuvens impedem a visualização dos processos envolvidos com a ocupação da terra, uma vez que o vapor d'água é opaco à radiação eletromagnética no espectro óptico. Esse fator de interferência representa a maior limitação no monitoramento por sensores ópticos, diminuindo a quantidade de imagens utilizáveis (MORAN et al., 1997), principalmente em regiões tropicais e subtropicais, que são muito influenciadas por massas de ar úmido, ocorrendo uma cobertura quase que permanente de nuvens (EVANS; COSTA, 2013; LOEBMANN et al., 2015) e tornando a aquisição de imagens ópticas um desafio (WULDER et al., 2015).

2.5. Radares de Abertura Sintética – SAR


Os radares são sistemas sensores ativos, apresentando como principal característica a sua independência da energia eletromagnética do Sol, ou das propriedades termais da Terra, possibilitando que o imageamento da superfície seja realizado a qualquer momento (DINIZ, 2019). O princípio básico de funcionamento dos radares consiste na emissão da radiação eletromagnética direcionada à superfície terrestre e na gravação da intensidade e do tempo de retorno da energia retrospalhada pelo alvo na superfície à medida que o sensor se desloca. (ULABY et al., 1986).

Os sistemas SAR simulam uma antena muito maior em comparação aos radares de abertura real (RAR) e são capazes de gerarem um número maior de pulsos em direção ao objeto, com isso, apresentam resoluções muito finas para grandes distâncias. Assim, obtém-se uma grande melhora na resolução em azimute devido ao aumento da antena (JENSEN, 2009).

Assim como mostra a Figura 2.2, os radares operam na faixa do espectro eletromagnético denominada microondas. Por operarem nesta faixa, possuem a grande vantagem de serem capazes de adquirir dados independentemente da iluminação solar e de serem pouco influenciados pelas condições atmosféricas, uma vez que a transmitância atmosférica é praticamente total para a faixa das microondas (BENEDITTI, 2010). Devido a essa característica, é possível obter o imageamento da superfície mesmo com cobertura de

nuvens ou neblina (DINIZ, 2019) e, por serem sensíveis à biomassa florestal e sua estrutura, permitem a discriminação de diferentes tipos de cobertura do solo em ambientes florestais (GUERRA et al., 2010).

Figura 2.2 - Espectro eletromagnético e bandas da região de micro-ondas.



Fonte: Dutra et al. (2003)

De acordo com Kasischke et al. (1997), a capacidade do sistema radar de penetração na vegetação aumenta à medida que o comprimento de onda aumenta. As regiões espectrais utilizadas exercem grande influência na obtenção das informações sobre os alvos, uma vez que a penetração das ondas é diretamente proporcional ao comprimento de onda da radiação eletromagnética. Com isso, os radares que operam em comprimentos de onda mais longos (bandas L e P) penetram no dossel, enquanto os de comprimentos de onda mais curtos (bandas C e X) interagem com as camadas superiores do dossel (OLDONI et al., 2020). Gama, Dos Santos e Mura (2016) obtiveram resultados consistentes e muito promissores utilizando sensores SAR de banda P e X para atualização dos inventários anuais necessários no manejo do plantio de eucalipto visando a produção de celulose

2.6. Ruído Speckle e filtros adaptativos

Uma das características das imagens SAR é sua aparência granular, onde aleatoriamente têm-se pixels de maior ou menor intensidade que o conjunto de pixels ao seu redor (LILLESAND et

al., 2004), sendo resultado de interferências construtivas e destrutivas da energia eletromagnética retroespalhada pelos alvos (SANT'ANNA; SIDNEI, 1994). Esse ruído é um efeito multiplicativo denominado Speckle, que dificulta análises como interpretação visual e classificação digital (HENDERSON; LEWIS, 1998), uma vez que diminui a habilidade do intérprete humano em fazer a análise visual da área de interesse (SANT'ANNA; SIDNEI, 1994). Nesse sentido, há a necessidade de alguns processamentos para redução do ruído Speckle, tais como a aplicação de *multilooking* ou de filtros espaciais.

O processamento *multilook* consiste em dividir a abertura sintética da antena em alguns setores, processando-os independentemente e somando-se em seguida cada um destes looks (RENNÓ, 1995). No entanto, quanto maior o número de looks empregados, maior será a perda na resolução em azimute (LEE et al., 1991) e menor será a quantidade de informações relacionadas à textura que poderão ser extraídas da imagem (SHI; FUNG, 1994). Com o objetivo de aumentar a relação sinal-ruído das imagens SAR, bem como preservar os detalhes finos existentes nas mesmas, diversos filtros espaciais redutores de ruído speckle têm sido propostos (SANT'ANNA; SIDNEI, 1994). De acordo com Sant'Anna e Mascarenhas (1996), a relação sinal-ruído da imagem filtrada é diretamente proporcional com a eficiência do filtro em reduzir o efeito Speckle.

Entre os filtros adaptativos muito utilizados na literatura, estão o filtro Frost, o Lee e o Kuan (DONG et al., 2001; KIM et al., 2007; LOPES et al., 1990; SHI & FUNG, 1994).

O filtro Frost é um filtro de convolução linear, que minimiza o ruído Speckle através de uma função de correlação espacial exponencial entre os pixels, que minimiza o erro quadrático médio e incorpora a dependência espacial dos pixels vizinhos (DINIZ, 2019).

O filtro Lee considera que a média e o desvio padrão de um pixel estará em um intervalo dado pela média e pelo desvio padrão de todos os pixels (LEE, 1980). O modelo multiplicativo do ruído é aproximado por um modelo linear e, posteriormente, o mínimo erro médio quadrático é aplicado ao modelo linear (SHI & FUNG, 1994).

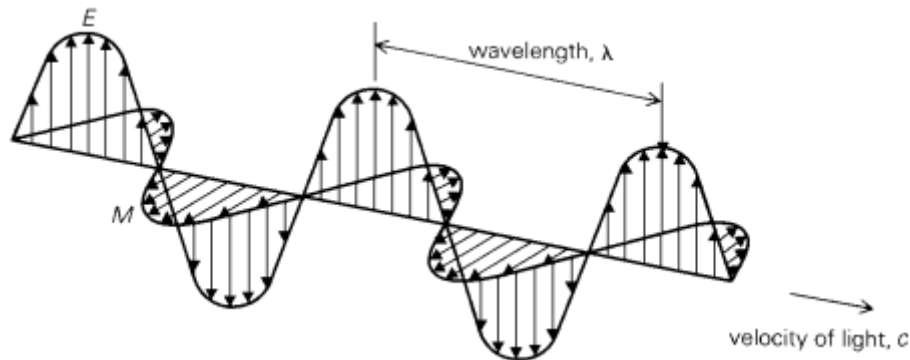
O filtro Kuan, assim como o filtro Lee, também considera o erro médio quadrático aplicado ao modelo linear. Entretanto, segundo Narayanan e Wahidabanu (2009) o filtro Kuan é um pouco mais avançado que o filtro de Lee em um fator, pois não envolve aproximação. Ele transforma o modelo de speckle multiplicativo na forma linear aditiva.

2.7. Polarizações

Assim como mostra a Figura 2.3, as ondas eletromagnéticas são oscilações de campos elétricos (E) e magnéticos (M), sendo que a variação de cada um desses campos dá origem ao

outro, de forma que essas referidas oscilações são autoinduzidas. Os campos elétrico e magnético são perpendiculares entre si, e a sua direção de propagação é perpendicular aos dois campos (JUNIOR, 2020).

Figura 2.3 - Onda eletromagnética com os dois componentes: campo elétrico (E) e campo magnético (M), ambas perpendiculares à direção de propagação.



Fonte: Aggarwal (2004)

A polarização da onda é definida no plano que contém o vetor campo elétrico, ela é o esboço do gráfico que o campo elétrico instantâneo traça com o tempo em um ponto fixo de observação. Assim, tomando o plano Terra como referência, definimos ondas polarizadas horizontalmente quando a vibração do campo elétrico é paralela à superfície, ou verticalmente quando a vibração é vertical à superfície (MACHADO, 2008). De acordo com Lewis et al. (1998), são possíveis quatro combinações de polarização: HH, VV, HV e VH, sendo que a primeira letra representa a polarização que a radiação eletromagnética é transmitida e a segunda representa a polarização que a radiação eletromagnética é recebida.

Os radares podem apresentar polarização simples (HH ou VV), polarização dupla (HH e HV, VV e VH ou HH e VV), polarização quádrupla (HH, VV, HV e VH) e, podendo ainda, ser completamente polarimétrico, que é quando apresentam as quatro combinações de polarização (HH, VV, HV e VH) e a fase relativa entre as polarizações (LEWIS et al., 1998). A polarização empregada pelo radar irá definir o grau de penetração e o tipo de interação da onda eletromagnética com os alvos, já que cada polarização do radar é mais sensível a certas características da vegetação. Os feixes de micro-ondas polarizados verticalmente (V) são mais sensíveis à estrutura vertical, enquanto as ondas polarizadas horizontalmente (H) são mais sensíveis às estruturas horizontais (DENIZE et al., 2019; MCNAIRN; BRISCO, 2004). As ondas copolarizadas (HH e VV) demonstram mais sensibilidade à dispersão de superfície,

enquanto as polarizações cruzadas (VH e HV), são mais sensíveis à dispersão de volume (DENIZE et al., 2019; VELOSO et al., 2017).

2.8. Mecanismos de espalhamento

O conhecimento dos mecanismos de interação entre os sinais SAR e as propriedades estruturais das florestas já foi investigado em diversos estudos (CHAMPION et al., 1998; COOPS; 2002, KASISCHKE et al., 1997). As características da cobertura florestal, rugosidade do terreno, umidade do solo e também os aspectos da imagem SAR, tais como polarização, ângulo de incidência e comprimento de onda são importantes determinar o sinal retroespalhado para a antena SAR

De acordo com Wang e Imhoff (1993), dentre os principais mecanismos de espalhamento de florestas estão o espalhamento superficial, espalhamento volumétrico e o *double bounce*. Jensen (2009) relaciona o mecanismo de espalhamento superficial à dispersão que ocorre na superfície do alvo, sendo dependente da sua rugosidade e da sua constante dielétrica. O espalhamento volumétrico acontece quando o sinal é refletido por uma infinidade de elementos de dispersão aleatoriamente orientados no dossel (RICHARDS, 2009). Já o espalhamento do tipo *double-bounce* acontece quando o sinal interage com uma superfície vertical adjacente a um plano horizontal, orientados para a frente de onda do radar, provocando um forte sinal de retorno para a antena, resultando em pixels claros na imagem (RICHARDS, 2009).

Liesenberg et al. (2016) e Martins et al. (2016) investigaram a sensibilidade de cada mecanismo na identificação dos componentes florestais. Componentes como solo exposto, corpos d'água e pastagem estão diretamente relacionados com o espalhamento superficial, uma vez que esses elementos possuem uma superfície mais lisa. O espalhamento volumétrico está relacionado a estruturas mais densas, com vários elementos capazes de dispersar o sinal emitido pelo radar, tais como as copas das árvores que compõem os dosséis florestais. Já sobre o espalhamento do tipo *double-bounce* no ambiente florestal, este liga-se fortemente com a relação entre solo e tronco, que geralmente formam um ângulo próximo a 90° entre si.

2.9. Coeficiente de retroespalhamento

Parte da radiação enviada pelo radar é absorvida, parte é refletida especularmente, outra parte é difundida dentro do alvo e outra, eventualmente, retorna para a antena para ser registrada e medida na forma de um sinal de retorno, servindo de base para a produção de uma imagem

de radar (NOERNBERG et al., 1999). O coeficiente de retroespalhamento (σ°) se refere à quantidade de energia espalhada pelo alvo em direção ao sensor, em relação à quantidade de energia que foi emitida pelo pulso de micro-ondas do sensor (RANEY, 1998), sendo que a potência recebida pela antena é diretamente proporcional à seção transversal de retroespalhamento (Ulaby e Dobson, 1989). De acordo com Novo e Costa (2005), o sinal recebido pelo sensor depende diretamente de dois tipos de variáveis, classificadas em variáveis do sensor e variáveis dos alvos. As variáveis do sistema sensor que controlam as interações entre a radiação de micro-ondas e a superfície terrestre são: comprimento de onda, ângulo de incidência, resolução espacial, direção de imageamento e polarização. Já as variáveis do alvo imageado são: rugosidade da superfície, forma geométrica, constante dielétrica e mecanismo de retroespalhamento.

Quando o alvo estudado é a vegetação, os parâmetros relacionados ao dossel, que influenciam no comportamento do retroespalhamento, são a distribuição tridimensional dos elementos espalhadores e a organização das moléculas de água do alvo (NOERNBERG et al., 1999), sendo o coeficiente de retroespalhamento expressado pela interação entre o espalhamento direto e a atenuação da radiação eletromagnética pelas camadas florestais, dossel, troncos e superfície (TOWNSEND, 2002). Parte da energia enviada pelo radar é retroespalhada pela superfície da vegetação, e outra parte da energia, dependendo das características do radar usado e da estrutura do alvo, penetra no dossel e é retroespalhada pelos elementos espalhadores (folhas, galhos etc.) dentro da vegetação e pelo solo (NOERNBERG et al., 1999).

A capacidade de penetração da radiação de micro-ondas no dossel da floresta depende do comprimento de onda do sistema utilizado. Quanto maior o comprimento de onda da radiação de micro-ondas, maior é sua capacidade de penetração tanto nos dosséis quanto nos solos (ELACHI, 1987). Assim, para sensores que utilizam a banda C e têm o comprimento de onda mais curto, o coeficiente de retroespalhamento será influenciado, principalmente, pelo retroespalhamento do topo do dossel, devido à baixa penetração das micro-ondas (LANG et al., 2008).

2.10. Sentinel-1

A criação do Programa Copernicus pela Comissão Europeia foi um grande marco na disponibilidade e acessibilidade de informação de dados, oferecendo serviços baseados em satélite de observação da Terra. O Programa Copernicus tornou-se o maior provedor de dados espaciais do mundo, fornecendo acesso completo, gratuito e aberto a dados de satélite,

principalmente adquiridos pelos satélites Sentinel (FILIPPONI, 2019). Entre as principais vantagens oferecidas pelos dados do Sentinel, estão a resolução espacial aprimorada e a alta frequência de revisita, tornando-os úteis para uma ampla gama de aplicações, tais como: detecção de alvos marítimos (BEZERRA, 2021), mapeamento de uso e cobertura do solo (DINIZ, 2019), detecção de desmatamento e mudanças em ecossistemas (CORREIA, 2021; RODRIGUES et al., 2019) e crescimento de culturas (MANDAL et al., 2020).

Atualmente, os dados adquiridos pela missão Sentinel-1 são disponibilizados gratuitamente, 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, 2023a). A constelação de satélites Sentinel-1 adquire dados de Radar de Abertura Sintética (SAR) nos modos de polarização simples (HH ou VV) e polarização dupla (HH/HV ou VV/VH). A operação funciona dia e noite, detectando com um instrumento de radar de abertura sintética de banda C operando a uma frequência central de 5,405 GHz, permitindo a aquisição de imagens, independentemente das condições meteorológicas e de iluminação (FILIPPONI, 2019).

Os dados Sentinel-1 Nível 1 são distribuídos pelo *Copernicus Open Access Hub* em dois tipos de produtos: *Single Look Complex* (SLC) e *Ground Range Detected* (GRD). Os produtos SLC consistem em dados SAR focalizados, georreferenciados, através de dados de órbita e altitude do satélite, são fornecidos em geometria de alcance inclinado (*slant range*) e consistem em dados complexos que preservam a informação de fase (ESA, 2023a). Já os produtos GRD, consistem em dados SAR já processados com multi-looking e projetados para o alcance do solo usando um modelo de elipsóide terrestre. As informações de fase são perdidas e o produto resultante tem resolução espacial aproximadamente quadrada e espaçamento de pixel quadrado com manchas reduzidas devido ao processamento de *multilooking* (ESA, 2023a).

O satélite Sentinel-1A funcionava em parceria com o satélite Sentinel-1B, obtendo dados mais finos e com melhor resolução temporal. Em agosto de 2022, a ESA anunciou que estavam encerradas as tentativas de retomar o funcionamento do radar de abertura sintética instalado no satélite Sentinel-1B, que estava indisponível devido a uma anomalia técnica (ESA, 2022). Vale ressaltar que apesar de o Sentinel-1A estar em perfeito funcionamento, ele já ultrapassou sua vida útil de sete anos. A boa notícia é que já houve a assinatura do contrato com a Arianespace, que garante o lançamento do terceiro satélite Copernicus Sentinel-1. Programado para decolar no novo foguete Vega-C da ESA do espaçoporto europeu na Guiana Francesa no primeiro semestre de 2023, o Sentinel-1C

continuará a tarefa crítica de fornecer imagens de radar importantes para uma ampla gama de serviços, aplicações e ciência (ESA, 2022).

2.11. Classificação da imagem

A classificação de imagens consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe através do reconhecimento de padrões, relacionando um objeto na imagem com uma classe temática, através de uma análise quantitativa do espaço de atributos da imagem (CRÓSTA, 1992; MATHER; TSO, 2009).

Os métodos de classificação de imagem podem ser agrupados em função da presença ou não de uma fase de treinamento, onde o analista interage com o computador. O método é considerado não-supervisionado quando o algoritmo classificador não utiliza nenhum conhecimento sobre as classes existentes na imagem, definindo a estratificação da cena e a atribuição de cada pixel a uma determinada classe com base em regras estatísticas pré-selecionadas, sem a interferência do analista (RICHARDS, 1986).

Já no método de classificação supervisionado, há a coleta e seleção de amostras de treinamento confiáveis. O algoritmo classificador opera com base na distribuição de probabilidade de cada pixel pertencer a cada uma das classes selecionadas (ADENIYI, 1985). Ou seja, o analista inicialmente treina o classificador, para que o algoritmo seja capaz de classificar os pixels que não possuem uma classe temática definida (MATHER, 1999).

As classificações podem ser pixel-a-pixel, quando o algoritmo utiliza a informação espectral de cada pixel para definir os padrões (MATHER; TSO, 2009) ou por segmentação, que é quando o algoritmo envolve uma primeira etapa de particionamento da imagem em regiões com diferentes atributos estatísticos (média, matriz de covariância e área) e uma segunda etapa de classificação de regiões, fundamentada na teoria de agrupamentos (BINS et al., 1993). A classificação píxel-a-píxel é mais simples e exige menor capacidade de processamento da máquina, em comparação com a classificação orientada à objeto.

2.12. Validação do desempenho da classificação

Após realizar a classificação de imagens digitais é necessário avaliar a sua exatidão, ou seja, a determinação de quão bom é o resultado da classificação em relação à realidade (NOVO, 2010). De acordo com Congalton e Green (1999), uma das formas de avaliar a exatidão de uma classificação é a utilização da matriz de confusão, que compara os resultados da classificação com os dados de referência. Essa matriz normalmente apresenta o número de linhas e o número

de colunas iguais ao número de classes espectrais do estudo (MENESES; ALMEIDA, 2012), sendo que as colunas representam os dados de referência, enquanto as linhas indicam os dados classificados pelo algoritmo de classificação. A diagonal principal indica a concordância entre estes dois grupos de dados (STORY; CONGALTON, 1986).

A partir da matriz de confusão pode desenvolver-se uma série de medidas estatísticas que concluem o processo de validação, como a acurácia global, erros de omissão e erros de comissão. A acurácia global da classificação é definida pela razão entre a soma do número de pixels das amostras classificadas corretamente (diagonal principal) pelo número total de pixels das amostras de treinamento. Já sobre os erros, deve-se levar em consideração os valores nas células marginais da matriz. No caso das linhas, os valores indicam o número de pixels que, pertencendo a uma determinada categoria, não foram incluídos nela (erros de Omissão). Já nas colunas, podemos observar os erros de comissão, isto é, pixels que se incluem em uma determinada categoria, mas que pertencente realmente a outra (CHUVIECO, 1990; CONGALTON, 1991; CONGALTON; GREEN, 1999; CONGALTON; GREEN, 2009; FIDALGO, 1995; LILLESAND et al., 2004).

Segundo Cohen (1960), podemos avaliar a acurácia de uma classificação por meio dos coeficientes de concordância, destacando-se o índice Kappa dentre os mais utilizados. Esse índice é uma das variáveis que podem ser quantificadas após construir a matriz de confusão, sendo um índice que retrata o grau de concordância dos dados e gera um aspecto de confiabilidade e precisão dos dados classificados (PERROCA; GAIDZINSKI, 2003). O índice Kappa é considerado uma padronização para representar os resultados das classificações, sendo recomendado para avaliar e comparar a exatidão das classificações, por representar completamente a matriz de confusão (BRITES et al., 1966). Fonseca (2000) relaciona os intervalos de valores desse índice, que varia de 0 a 1, a níveis nominais qualitativos para expressar a qualidade dos resultados, conforme destacado na Tabela 2.1.

Tabela 2.1- Agrupamento qualitativo do coeficiente kappa.

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

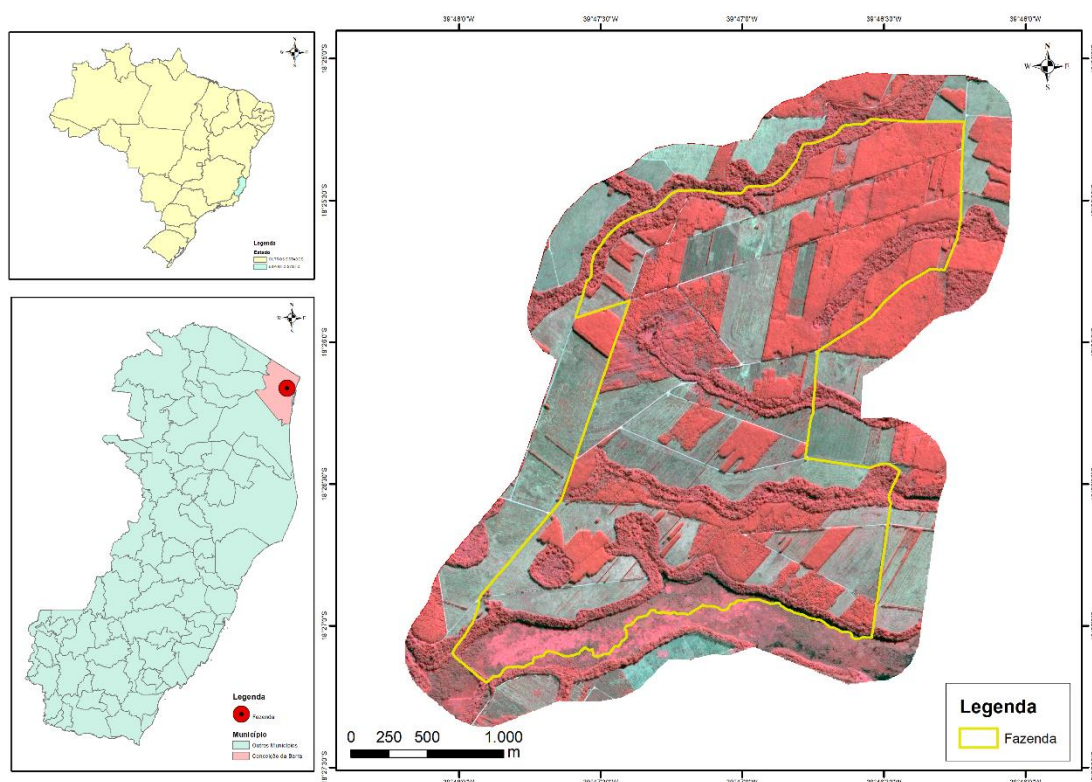
Fonte: Fonseca (2000)

3. MATERIAL E MÉTODOS

3.1. Área de estudo

A área de estudo é uma fazenda localizada em Conceição da Barra, município que fica na região norte do estado do Espírito Santo, nas coordenadas 39°47'3''O e 18°26'14''S, totalizando uma área de 590 hectares (Figura 4). A fazenda é utilizada para o plantio de eucalipto pela empresa Suzano S.A., contando com uma área de plantio de 428,15 hectares divididas entre 29 unidades de produção (UP), sendo que algumas dessas UPs se encontram com floresta em pé de boa qualidade, outras com floresta danificada e algumas com solo exposto.

Figura 3.1 – Localização da área de estudo.



Fonte: do autor (2023)

Segundo a classificação de Köppen, a região é caracterizada por apresentar um clima tropical chuvoso (Tipo Af), sem estação seca no inverno. A temperatura média anual é de 24,4 °C e a média anual de precipitação total é de 1.175 mm, sendo que a média da temperatura do mês mais frio é superior a 18 °C e a média da precipitação do mês mais seco é superior à 60 mm (ALVARES et al, 2013). Além disso, segundo dados meteorológicos do Instituto Capixaba De Pesquisa Assistência Técnica E Extensão Rural - INCAPER, a precipitação é sazonalmente dividida em dois períodos: um chuvoso, entre os meses de outubro a abril, que corresponde a cerca de 70% do total acumulado anual e um período menos chuvoso entre os meses de maio a

setembro, que corresponde a cerca de 30% do total. Teixeira et al. (2009) observou que havia cobertura de nuvens em 41% dos dias do verão e em 22% dos dias do inverno no estado do Espírito Santo em 1997.

De acordo com o Atlas da Mata Atlântica (IEMA, 2018) publicado pela Secretaria Estadual de Meio Ambiente e Recursos Hídricos - SEAMA, a principal atividade agrícola em Conceição da Barra é a Silvicultura, com o predomínio da cultura do Eucalipto, que ocupa 37,4% do território do município.

3.2. Aquisição dos dados SAR

Para a realização deste estudo foram utilizados dados do sensor Sentinel-1, que opera na banda C e são disponibilizados gratuitamente pelo site da Agência Espacial Europeia (ESA). Os dados foram adquiridos no modo de Faixa Interferométrica Larga (IW), que é o principal modo de aquisição sobre a terra e adquire dados com uma faixa de imageamento de 250 km e com resolução de 5 por 20 metros (ESA, 2023a).

O modo IW captura três subfaixas usando a Observação do Terreno com Varreduras Progressivas SAR, sendo utilizado neste estudo a subfaixa referente à área de estudo IW1, nas polarizações VV e VH. Os dados SAR adquiridos são do dia 25/07/2022 e possuem nível 1 de processamento e são de dois formatos diferentes: SLC e GRD. Os dados SLC (Single Look Complex), consistem em dados SAR focalizados e georreferenciados através de informações de órbita e atitude do satélite e são fornecidos em geometria de alcance inclinado (Slant Range). Já os dados GRD (Ground Range Detected), consistem em dados SAR focalizados que foram focados, processados através de multilooking e projetados para o alcance do solo usando o modelo de elipsóide terrestre WGS84, resultando em pixels de resolução e espaçamento aproximadamente quadrados, havendo a redução do ruído speckle, mas também uma redução na resolução espacial (ESA, 2023a).

3.3. Dados auxiliares

Para a validação da classificação foi utilizada uma imagem do sensor multiespectral a bordo do satélite SPOT6 do dia 08/06/2022, sendo essa a data mais próxima da data de aquisição da imagem do sensor SAR com imagem de alta resolução disponível. A imagem não é gratuita e foi disponibilizada pela Suzano S.A., sendo realizado o download utilizando parte do pacote de dados que a empresa adquiriu através da plataforma da Visiona Tecnologia Espacial.

A Tabela 3.1 mostra que o sensor apresenta cinco bandas espectrais, quatro coloridas e uma pancromática preto e branca de melhor resolução espacial, permitindo melhorar a resolução da composição colorida de 6 m para 1,5 m.

Tabela 3.1 - Características das bandas espectrais do sensor SPOT6.

Banda	Intervalo de comprimento de onda (nm)	Resolução espacial (m)
Pancromática (B0)	450 - 745	1,5
Azul (B1)	450 - 520	6
Verde (B2)	530 - 590	6
Vermelho (B3)	625 - 695	6
Infravermelho próximo (B4)	760 - 890	6

Fonte: adaptado de SPOT Imagery User Guide

Para comparar o desempenho dos resultados das classificações a partir de dados SAR com o desempenho das classificações já feitas no sistema monitora utilizando dados ópticos, foi utilizada uma imagem do sensor multiespectral a bordo do satélite Sentinel-2A do dia 29/07/2022. Este sensor possui dados gratuitos que são disponibilizados pela Agência Espacial Europeia (ESA), com uma resolução temporal de 10 dias.

Este sensor apresenta treze bandas espectrais, com sua resolução espacial variando de 10 m a 60 m, de acordo com essas bandas (ESA, 2023b). Na Tabela 3.2 estão as descrições das quatro bandas espectrais que utilizamos para compor as imagens coloridas e calcular o Índice de Vegetação da Diferença Normalizada (NDVI), assim como feito pelo sistema monitora.

Tabela 3.2 - Características das bandas espectrais do sensor Sentinel-2.

Banda	Comprimento de onda central (nm)	Resolução espacial (m)
Azul (B2)	490	10
Verde (B3)	560	10
Vermelho (B4)	665	10
Infravermelho próximo (B8)	842	10

Fonte: adaptado de ESA (2023b)

Além disso, foram utilizados dois vetores fornecidos pela Suzano S.A.: um da área total da fazenda que foi realizado o estudo e outro com a espacialização das UPs que pertencem à essa fazenda, permitindo identificar as áreas que são disponíveis para plantio dentro da área de estudo.

3.4. Metodologia Aplicada

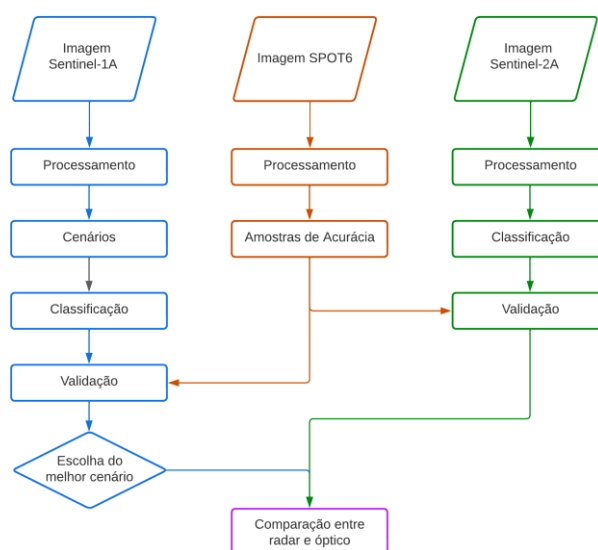
A Figura 3.2 mostra o fluxograma geral da metodologia que foi utilizada no processamento e análise dos dados de acordo com os objetivos propostos.

Os dados SLC e GRD do sensor SAR Sentinel-1A foram processados com a aplicação de duas janelas diferentes do filtro Lee (3x3 e 9x9) para a obtenção dos coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 e $\frac{\sigma_{VH}^0}{\sigma_{VV}^0}$). Para cada um desses coeficientes foram definidos valores de corte, onde pixels com valores superiores a esse limiar foram classificados como vegetação e pixels com valores inferiores foram classificados como falha de plantio.

Para avaliar o desempenho classificatório destes atributos, foi utilizada uma imagem SPOT 6 de alta resolução espacial para coletar amostras de acurácia, necessárias no cálculo das matrizes de confusão. Após a validação da classificação, foi realizada a comparação do desempenho das classificações dos diferentes cenários obtidos com os coeficientes de retroespalhamento advindos dos dados de radar.

Para avaliar o potencial do mapeamento obtido com os dados de radar foi realizada a comparação do melhor cenário obtido com os dados do sensor SAR (Sentinel-1A) com a detecção de falhas de plantio realizada pelo sensor óptico (Sentinel-2A), que foi processado e classificado de acordo com a mesma metodologia utilizada pelo sistema monitora. Nos próximos tópicos, todas as etapas serão descritas com detalhes.

Figura 3.2 - Fluxograma da metodologia geral desenvolvida.

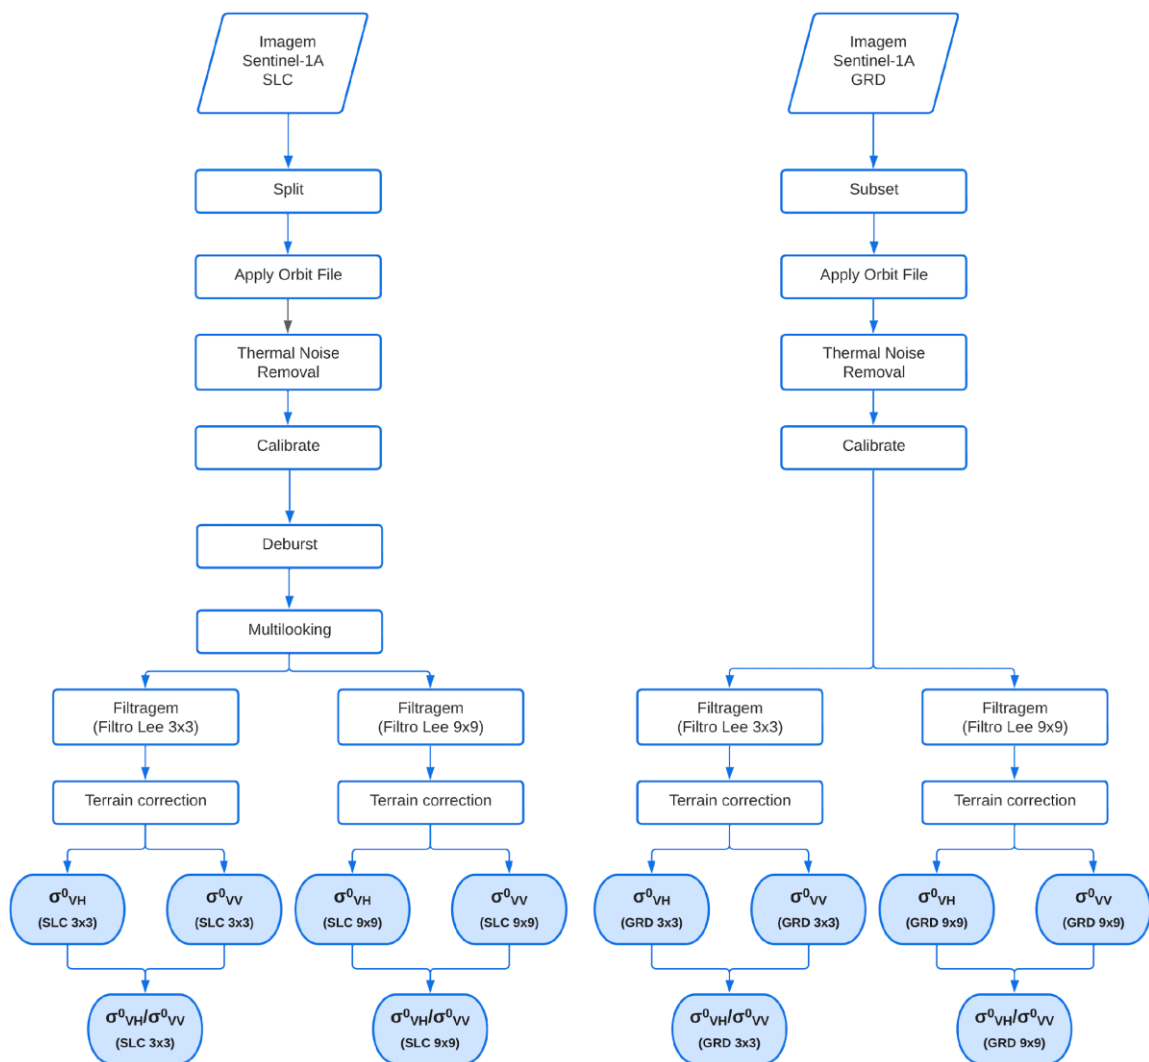


Fonte: do autor (2023)

3.5. Processamento dos dados SAR

O fluxograma da Figura 3.3 mostra as etapas de processamento, que são diferentes para os dados de radar no formato SLC e GRD. Para realizar o processamento e extrair os coeficientes de retroespalhamento dos dados SAR, foi utilizada a versão 8.0 do software livre SNAP (SeNtinel Applications Platform), desenvolvido pela ESA (European Space Agency).

Figura 3.3 - Fluxograma das etapas de processamento das imagens.




Fonte: do autor (2023)

Foi utilizada a Sentinel-1 toolbox (S1TBX), que faz parte do software SNAP e suporta leitura, exibição, processamento e gravação de dados de vários satélites de sensoriamento remoto. A caixa de ferramentas inclui várias ferramentas polarimétricas e interferométricas para calibração, co-registro, filtragem, fusão de subfaixas e conversão de dados (MANDAL et al., 2019).

3.5.1. Dados SLC

Para os dados SLC, a primeira ferramenta utilizada foi a *Split*, executada para extrair a área de interesse presente na sub-faixa IW1, deixando a cena mais leve e melhorando a velocidade de processamento das etapas posteriores.

Figura 3.4 – Resultado da ferramenta *Split*.



Fonte: do autor (2023)

Como os vetores de estado de órbita, contidos nas informações de metadados dos produtos SAR, geralmente não são precisos, foi realizada a operação *Apply Orbit File*, que realiza o download e atualização automática dos vetores de estado de órbita e fornece informações precisas de posição do satélite e informações de velocidade.

As imagens do Sentinel-1 são afetadas por um ruído térmico aditivo, principalmente na polarização VH (PARK et al., 2017). Por isso, foi realizada a operação *Thermal Noise Removal* para diminuir os efeitos desse ruído entre as sub-faixas, reduzindo a descontinuidade entre elas. Em seguida, foi aplicado o *Calibrate* para converter os valores de número digital dos pixels em retroespalhamento calibrado radiométricamente. Através da Equação 2, essa operação retorna os coeficientes de retroespalhamento (σ_{VH}^0 e σ_{VV}^0), que medem a quantidade de energia refletida pela seção transversal para o receptor, por unidade de área no terreno.

$$\sigma_i^0 = \frac{DN_i^2}{A_i^2} \quad (2)$$

Onde:

σ_i^0 = valores de retroespalhamento por unidade de área no alcance do terreno.


DN_i = valores de números digitais dos pixels.

A_i = Coeficiente de calibração - tabelas de pesquisa de calibração (LUTs)

Para obtenção de uma imagem contínua, sem as linhas pretas de separação e sem as linhas redundantes entre os bursts, foi aplicada a operação *Deburst*, que realiza uma retificação

da imagem, possibilitando que esta seja reamostrada para uma grade comum de espaçamento de pixels em range e azimute.


Figura 3.5 – Resultado da ferramenta *Deburst*.



Fonte: do autor (2023)

Foi aplicada a operação *Multilooking* com quatro looks, sendo um em azimute e quatro em range, visando reduzir o ruído speckle e regularizar as dimensões dos pixels (LEE; POTTIER, 2009). Como resultado, a imagem apresenta menos ruído e um espaçamento de pixel aproximadamente quadrado, tendo sido convertida de um alcance oblíquo para um alcance no terreno (ESA, 2023a).


Figura 3.6 – Resultado da ferramenta *Multilooking* quatro looks.



Fonte: do autor (2023)

Diniz (2019) analisou de forma quantitativa os filtros Lee, Sigma Lee e Gamma para redução do ruído Speckle e constatou que o filtro Lee provocou a maior diminuição no coeficiente de variação da imagem, apresentando uma maior redução no CV em todas as janelas de filtragem, quando comparado aos filtros Sigma Lee e Gamma. Com isso, na etapa de filtragem desse estudo foi utilizado o filtro Lee com duas variações de janelas: 3x3 e 9x9.


Figura 3.7 – Comparação do resultado do filtro Lee para as janelas 3x3 e 9x9.



Fonte: do autor (2023)

De acordo com Wegmuller (1999), a geocodificação é necessária para combinar as informações derivadas dos dados SAR com dados in-situ ou informações de outros sensores. Para isso, utilizamos a ferramenta *Range Doppler Terrain Correction*, que corrige as distorções geométricas causadas pela topografia, como encurtamento e sombras, usando o Modelo Digital de Elevação SRTM (*Shuttle Radar Topography Mission*) para corrigir a localização de cada pixel. Com isso, houve a compensação das distorções relacionadas à geometria das imagens, para que a sua representação geométrica seja a mais próxima possível do mundo real.

Figura 3.8 – Resultado da ferramenta *Range Doppler Terrain Correction* utilizando o MDE SRTM.



Fonte: do autor (2023)

Por fim, utilizando os produtos σ_{VH}^0 e σ_{VV}^0 corrigidos geometricamente, foi obtida a Razão Crespolarizada através da Equação 3.

$$RC = \frac{\sigma_{VH}^0}{\sigma_{VV}^0} \quad (3)$$

Onde:

RC = Razão Crespolarizada.

σ_{VH}^0 = Coeficiente de Retroespalhamento para a polarização VH.

σ_{VV}^0 = Coeficiente de Retroespalhamento para a polarização VV.

3.5.2. Dados GRD

Conforme é possível observar na Figura 6, o processamento dos dados GRD para gerar os coeficientes de retroespalhamento é bem semelhante ao procedimento utilizado para os dados SLC, mas não são iguais. O processamento dos dados GRD se difere em alguns pontos devido a algumas características diferentes, quando comparadas ao formato SLC.

Os dados GRD não são divididos em faixas (IW1, IW2 e IW3) e nem possuem bursts como os dados SLC, se apresentando como uma única cena abrangendo toda a área imageada. Essa característica impossibilita a utilização da operação *Split* para diminuir o tamanho da imagem e aumentar a velocidade de processamento, então é utilizada a operação *Subset*, onde selecionamos manualmente um polígono e exportamos uma cena abrangendo apenas a área de interesse, evitando que o processamento fique lento devido ao tamanho do arquivo. Por não conter bursts, a operação *Deburst* é dispensada para os dados GRD.

Outro ponto é que como os produtos GRD consistem em dados SAR focados, projetados para um alcance no terreno e já processados através de *Multilooking*, não há a necessidade de aplicarmos essa operação novamente.

3.6. Processamento dos dados ópticos

3.6.1. Dados SPOT6

O sistema visual humano não é capaz de diferenciar uma grande quantidade de tons de cinza, conseqüentemente, apresenta limitações na identificação e compreensão das informações contidas na imagem monocromática de uma única banda espectral. Entretanto, o sistema visual humano é capaz de discernir uma gama infinitamente maior de cores (CROSTA, 1993; GONZALEZ; WOODS, 2000).

Assim, para se obter uma imagem de fácil interpretação, permitindo a visualização da imagem colorida, tanto na cor verdadeira (composição B3-B2-B1) quanto na falsa cor (composição B4-B3-B2) foi utilizada a ferramenta *Composite Bands* disponível no ArcToolbox, do software ArcGIS para Desktop, versão 10.6 (ESRI, 2016), essa ferramenta permitiu combinar as bandas do azul (B1), verde (B2), vermelho (B3) e infravermelho próximo (B4) do sensor SPOT6 para formar uma imagem multibanda com resolução espacial de 6 metros.

Para melhorar a resolução espacial da imagem, foi utilizada a ferramenta *Create Pan-sharpened Raster Dataset*, que combina um conjunto de dados raster pancromático de alta resolução com um conjunto de dados raster multibanda de resolução mais baixa para criar um conjunto de dados raster multibanda de alta resolução para análise visual (ESRI, 2021a). Portanto, foi realizada a combinação da banda 0 (pancromática) de resolução espacial de 1,5 metros com o raster multibanda obtido na etapa anterior, de resolução espacial de 6 metros, e obtemos um raster multibanda com resolução espacial de 1,5 metros, permitindo visualizar e interpretar as informações da imagem com maior facilidade e precisão.

3.6.2. Dados Sentinel-2A

Para o processamento dos dados ópticos do sensor multiespectral a bordo do satélite Sentinel 2A, também foram utilizadas ferramentas disponíveis no ArcToolbox, do software ArcGIS para Desktop, versão 10.6. Através da ferramenta *Composite Bands*, combinamos as bandas do azul (B2), verde (B3), vermelho (B4) e infravermelho próximo (B8) do sensor Sentinel 2A, obtendo uma imagem multibanda com resolução espacial de 10 metros.

Para melhorar a diferenciação entre regiões de plantio, com biomassa fotossinteticamente ativa, de regiões com falhas de plantio, ocorrências e solo exposto na imagem, foi gerado o NDVI (ROUSE et al., 1973) a partir das bandas do vermelho (B4) e infravermelho próximo (B8), utilizando a ferramenta *Raster Calculator*, que constrói e executa operações Map Álgebra a partir dos valores de pixel dos rasters em uma interface semelhante a uma calculadora (ESRI, 2021b).

3.7. Classificação dos dados SAR


3.7.1. Método de classificação

O método de classificação dos dados obtidos pelos diferentes cenários de processamento das cenas do sensor SAR Sentinel-1A será o mesmo utilizado pelo sistema monitora, onde é

adotado um valor de corte e, os pixels são classificados um a um como plantio ou como falha, de acordo com a condição que atendem. O valor de corte é diferente para cada um dos cenários obtidos.

A Figura 3.9 ilustra um exemplo dessa classificação, onde pixels com valores iguais ou superiores à 6 são classificados como plantio e pixels com valores inferiores à 6 são classificados como falha.

Figura 3.9 – Exemplo de classificação pixel a pixel.



Fonte: do autor (2023)

3.7.2. Definição dos valores delimitadores de classes


Para definir os valores de corte de cada um dos cenários, foi necessário conhecer o padrão dos valores de pixel das doze cenas obtidas no processamento das imagens de radar. Utilizando a versão 3.22.4 do QGIS, que é um software de código aberto multifuncional, que pode ser usado para criação, edição, análise e mapeamento de dados espaciais (QGIS, 2023a), foram criados dois vetores do tipo polígono chamados “Falha” e “Plantio” e, com o auxílio da composição falsa cor da imagem SPOT6, foram desenhados três polígonos georreferenciados para cada uma das classes estudadas.

Foi utilizada a ferramenta *Recortar Raster Pela Camada de Máscara* (QGIS, 2023b) para gerar dois novos rasters para cada cenário: um contendo apenas pixels pertencentes aos polígonos de plantio e outro contendo apenas os pixels pertencentes aos polígonos de falha. Foi utilizada a funcionalidade de Executar Processo em Lotes para conseguir gerar todos os 24 rasters (um de plantio e um de falha para cada um dos doze cenários) de uma única vez e agilizar o processo. Em seguida, foi utilizada a ferramenta *Reporta Camada Raster de Valor Único* (QGIS, 2023c), que retorna a contagem de cada valor único de pixel em dados de camada raster. A ferramenta também foi executada em lotes e obtivemos 24 planilhas com as informações de valores dos pixels e frequência.

Através do software Microsoft Excel (2021), foi organizada uma aba para cada cenário, contendo a frequência dos valores de pixels de plantio e de falha. Em seguida, foram gerados os gráficos Box-plot (ou gráfico de caixa), que é um gráfico estatístico que possibilita representar a distribuição de um conjunto de dados com base em alguns parâmetros quantitativos. De acordo com Capela e Capela (2011) o Box-plot permite avaliar a simetria dos dados e sua dispersão, sendo especialmente adequado para a comparação de dois ou mais conjunto de dados correspondentes às categorias de uma variável.

De forma geral, esses gráficos incluem a mediana, o 1º e o 3º quartil, os valores mínimos e máximos e eventuais outliers e extremos (MAROCO, 2007). A Figura 3.10 mostra os elementos desses gráficos e o que cada um representa sobre o conjunto de dados analisado.

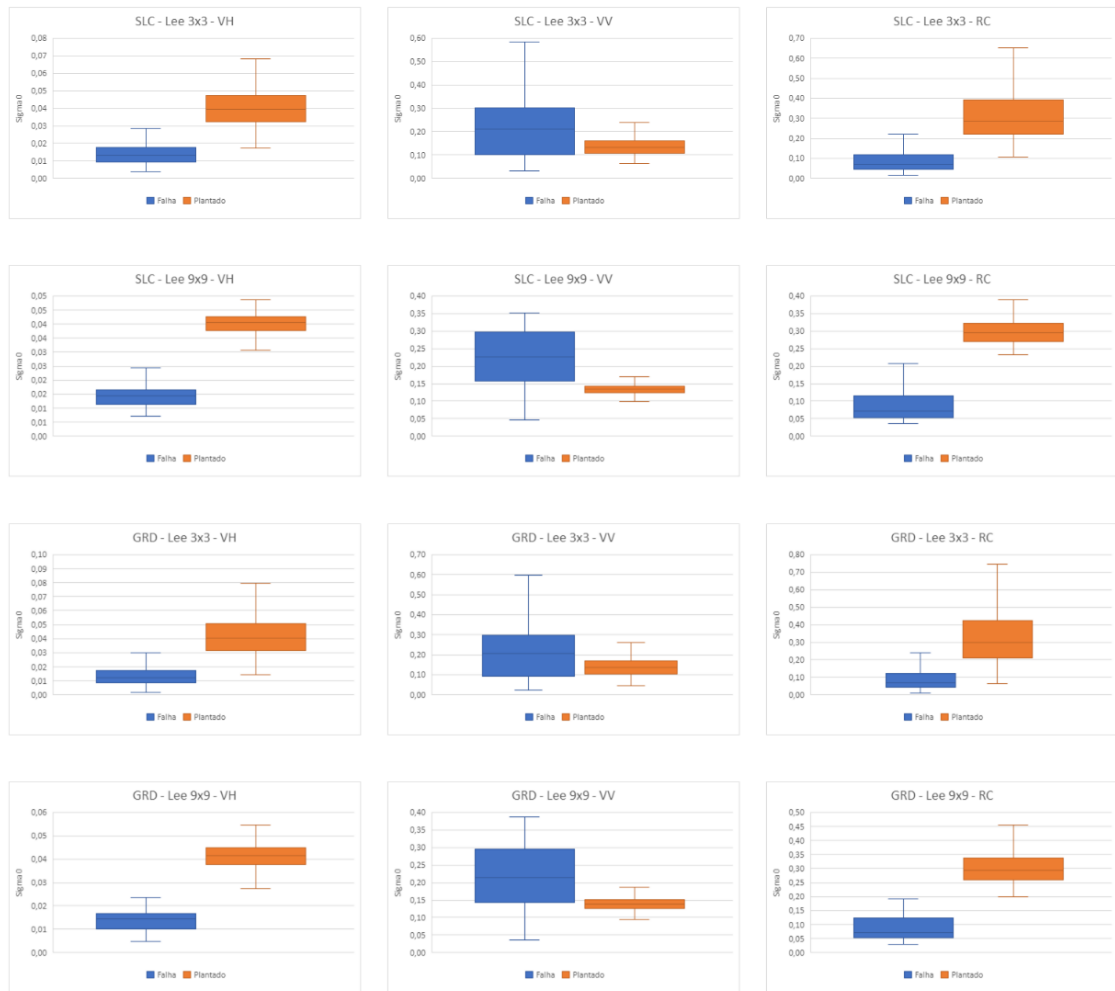
Figura 3.10 – Elementos de um gráfico Box-plot.



Fonte: Neto (2017)

A Figura 3.11 mostra os respectivos gráficos Box-plot obtidos através dos dados de valor e frequência dos pixels de plantio e falha para cada um dos cenários estudados.

Figura 3.11 – Gráficos Box-plot obtidos para os cenários estudados.



Fonte: do autor (2023)

A partir da interpretação visual dos gráficos, foram definidas as premissas para a definição dos valores delimitadores das classes que serão utilizados na classificação das imagens. Para os dados de σ^0 nas polarizações VH e RC, a distribuição dos pixels ficaram mais bem definidas, podemos observar que os pixels da classe plantada são concentrados em intervalos de maior valor e os pixels da classe falha são concentrados em intervalos de menor valor. Para essas polarizações, foi observado que o valor do Q3 (75% dos dados são menores) da classe falha é menor que o Q1 (75% dos dados são maior) da classe plantada. Assim, foi definido o valor de corte através da Equação 4.

$$VC = \frac{LS_{Falha} + Li_{Plantio}}{2} \quad (4)$$

Onde:

VC = Valor de corte.

LS_{Falha} = Valor do limite superior da classe falha.

$Li_{Plantio}$ = Valor do limite inferior da classe plantada.

Já para os dados de σ^0 na polarização VV, a distribuição dos pixels não ficou muito bem definida, dificultando a diferenciação das classes por agrupamento de valor. Podemos observar que, de maneira geral, que para os dados dessa polarização os pixels da classe falha têm uma distribuição mais dispersa, enquanto os pixels da classe plantada apresentam uma distribuição mais concentrada. Além disso, na maioria dos casos os intervalos interquartílicos das duas classes se sobrepõem, apresentando medianas com valores próximos, o que dificulta a separação das duas classes. Baseado na análise visual, foi definido que o valor do Q3 da classe plantada seria adotado como valor de corte na classificação das imagens da polarização VV.

A Tabela 3.3 mostra os valores de corte e as premissas para classificação das imagens, definidos de acordo com as regras citadas acima.

Tabela 3.3 – Valores de corte e premissas de classificação para os diferentes cenários estudados.

Cenário	Tipo	Filtro	Polarização	Valor de corte	Classificação	
					Falha	Plantio
S3VH	SLC	Lee 3x3	VH	0,023	< 0,023	≥ 0,023
S3VV	SLC	Lee 3x3	VV	0,161	≥ 0,161	< 0,161
S3RC	SLC	Lee 3x3	RC	0,164	< 0,164	≥ 0,164
S9VH	SLC	Lee 9x9	VH	0,027	< 0,027	≥ 0,027
S9VV	SLC	Lee 9x9	VV	0,144	≥ 0,144	< 0,144
S9RC	SLC	Lee 9x9	RC	0,220	< 0,220	≥ 0,220
G3VH	GRD	Lee 3x3	VH	0,022	< 0,022	≥ 0,022
G3VV	GRD	Lee 3x3	VV	0,168	≥ 0,168	< 0,168
G3RC	GRD	Lee 3x3	RC	0,152	< 0,152	≥ 0,152
G9VH	GRD	Lee 9x9	VH	0,025	< 0,025	≥ 0,025
G9VV	GRD	Lee 9x9	VV	0,151	≥ 0,151	< 0,151
G9RC	GRD	Lee 9x9	RC	0,195	< 0,195	≥ 0,195

Fonte: do autor (2023)

3.7.3. Classificação


As etapas de classificação e validação dos resultados foram executadas no software ArcGIS para Desktop, versão 10.6. A ferramenta *Clip Raster* foi utilizada para recortar as

imagens dos 12 cenários pela extensão do vetor da fazenda de estudo, assim, diminuindo o tempo gasto com a classificação das cenas.

A ferramenta *Reclassify*, que é capaz de mudar os valores dos pixels dos rasters baseado em parâmetros pré-estabelecidos, foi utilizada para reclassificar os valores contínuos dos pixels em duas classes: Falha (Classe 1) e Plantada (Classe 2). Assim como explícito na Figura 12, nessa ferramenta, o raster obtido em cada cenário entra como input e definimos um valor de corte VC, onde os pixels com valores superiores ao VC são classificados como plantada e os inferiores como falha, ou vice-versa. Tanto os valores de corte (VC), quanto as regras de classificação para cada um dos cenários foram apresentadas na Tabela 3.3.

A classificação foi realizada para os 12 cenários deste estudo. A Figura 3.12 mostra os resultados dos processos apresentados neste tópico, onde a entrada é um raster com valores de contínuos de retrospalhamento e o resultado é um raster com apenas dois valores, 1 representando a classe falha e 2 representando a classe plantada.

Figura 3.12 – Aplicação das ferramentas *Clip Raster* e *Reclassify* na imagem do cenário S3VH.




Fonte: do autor (2023)

3.8. Validação da classificação

3.8.1. Amostras de acurácia

As amostras de acurácia foram obtidas através de uma interpretação humana da cobertura do solo, baseado numa imagem SPOT6 de 1,5 metros de resolução espacial. A partir do vetor das Unidades de Produção (UP) da fazenda de estudo, utilizando a imagem SPOT6 como base do mapeamento, foram geradas as amostras de acurácia. Dentro da área de cada UP, consideramos que deveria haver uma floresta de eucalipto com copa fechada, foi então expurgado dessa área de plantio as partes que estavam com solo exposto, sendo estas classificadas como falha. A Figura 3.13 mostra o processo de obtenção das amostras de acurácia.

Figura 3.13 – Obtenção das amostras de acurácia a partir do vetor de Unidade de Produção.



Fonte:


Fonte: do autor (2023)

3.8.2. Matriz de confusão

Utilizando a ferramenta Create Accuracy Assessment Points do software ArcGIS para Desktop, versão 10.6 (ESRI, 2016), foram criados 2.000 pontos para avaliar a precisão pós-classificação. Esses pontos foram distribuídos aleatoriamente dentro de cada classe, onde cada classe tem um número de pontos proporcional à sua área relativa e, receberam a classificação 1 ou 2 no campo “Ground Truth”, baseado no vetor da amostra de acurácia.

A ferramenta *Update Accuracy Assessment Points* utilizou o arquivo shapefile dos pontos obtidos na etapa anterior e atualizou os atributos do campo “Classified” na tabela de atributos para permitir a comparação entre os pontos da imagem classificada e os pontos de acurácia. Semelhante à etapa anterior, cada ponto recebeu a classificação 1 ou 2, mas dessa vez no campo “Classified” e sendo baseado na imagem classificada.

Figura 3.14 – Obtenção da tabela comparativa entre pontos classificados x pontos de acurácia.



Fonte: do autor (2023)

A Figura 3.14 exemplifica o uso e resultado da aplicação dessas duas ferramentas e mostra o resultado da classificação na tabela comparativa. Em verde, são pontos que foram

classificados corretamente, nesse caso, foram classificados como plantio e realmente eram plantios. Já em vermelho, temos pontos classificados incorretamente como falha, pois de acordo com o vetor de acurácia, na verdade eram pontos de plantio.

A partir dos dados da tabela comparativa, foi utilizada a ferramenta *Compute Confusion Matrix* para calcular uma matriz de confusão com base em erros de omissão e comissão e, em seguida, derivar um índice kappa de concordância entre o mapa classificado e os dados que são considerados verdadeiros. Os valores de Acurácia Global, Acurácia do Produtor e Acurácia do usuário também foram calculados pela ferramenta.

3.9. Comparação com o sensor óptico

Com o intuito de comparar as classificações obtidas utilizando os dados de radar com as classificações resultantes do sistema Monitora, foram utilizadas imagens do sensor Sentinel-2A obtidas no dia 29/07/2022, data próxima às imagens SAR e SPOT6.

A partir dos dados de NDVI resultantes do processamento dos dados ópticos Sentinel-2A, foi realizada a classificação da imagem. Foi utilizada a ferramenta *Reclassify* para reclassificar os pixels de acordo com os parâmetros adotados pelo sistema Monitora, onde os pixels com valores superiores à 0,33 foram classificados como plantio classe 2) e os pixels com valores inferiores foram classificados como falha (classe 1). Após a classificação, a matriz de confusão foi computada seguindo o mesmo procedimento utilizado para a validação dos dados SAR.

A partir da classificação obtida com o Sentinel-2A foi possível realizar a comparação entre a detecção de falhas de plantio com um sensor óptico e a detecção obtida pelos dados de radar do cenário que obteve o melhor desempenho classificatório.

4. RESULTADOS

4.1. Análise exploratória dos coeficientes de retroespalhamento

Por meio da análise exploratória, ao analisar a separabilidade das classes nos gráficos box-plot (Figura 3.11), é notório que a discriminação entre as classes de falha e plantio foi melhor em alguns cenários do que em outros.

A discriminação entre as duas classes nos cenários das polarizações VH e RC foram melhores, não havendo sobreposições entre intervalos interquartílicos. Houve sobreposição entre o limite superior da classe falha e limite inferior da classe plantada nessas polarizações para o filtro Lee 3x3, o que não ocorreu para o filtro Lee 9x9, indicando uma boa separabilidade dos grupos de pixels das duas classes. Já para os cenários da polarização VV, houve grande

confusão entre os grupos de pixels, visto que para a janela 3x3 do filtro Lee pudemos observar que o intervalo interquartilico da classe plantada está completamente dentro do intervalo interquartilico da classe falha. Para a janela 9x9, os intervalos inter quartílicos não se sobrepõem, mas os pixels da classe plantada (com exceção dos outliers) estão completamente contidos no intervalo entre o limite superior e inferior da classe falha, implicando em uma grande dificuldade de distinção dessas classes.

No geral, quando comparamos os gráficos dos cenários onde foram utilizados a janela 9x9 do filtro Lee, é notório que os gráficos têm uma aparência mais achatada do que os gráficos da janela 3x3. Isso indica que os valores de coeficiente de retroespalhamento de cada uma das classes para a janela 9x9 são mais próximos entre si do que os valores para a janela 3x3. Diniz (2019) observou que houve uma diminuição crescente dos valores do Coeficiente de Variação (CV) das janelas 3x3 a 9x9, sendo possível observar uma redução do ruído Speckle, aumento do borramento das imagens e suavização das bordas à medida que a janela de filtragem aumenta.

Quando comparamos os gráficos dos dados SLC com os dos dados GRD, para a mesma polarização e janela de filtro, não é possível observar grandes diferenças. Os gráficos são muito semelhantes, tanto visualmente quanto se observarmos os valores dos quartis, da mediana e dos limites superiores e inferiores

4.2. Resultado da classificação

Para os cenários analisados, a Tabela 4.1 mostra os valores do índice Kappa e acurácia global (AC), assim como o conceito da qualidade da classificação de acordo com o proposto por Fonseca (2000), que foram obtidos a partir da metodologia apresentada no tópico 3.7.

Nota-se que o cenário G9VH atingiu o conceito de “Excelente”, se destacando como o melhor desempenho entre os cenários avaliados, com uma acurácia global de 91,4% e número Kappa igual a 0,826. Já os cenários que foram obtidos com a classificação utilizando a polarização VV resultaram nos piores desempenhos, apresentando número Kappa inferior à 0,1 e recebendo o conceito de “Ruim”.

Tabela 4.1 – Acurácia Global, Kappa e desempenho para todos os cenários avaliados.

Cenário	Tipo	Filtro	Polarização	Acurácia Global	Número Kappa	Desempenho
S3VH	SLC	Lee 3x3	VH	0,884	0,766	Muito Bom
S3VV	SLC	Lee 3x3	VV	0,546	0,058	Ruim
S3RC	SLC	Lee 3x3	RC	0,784	0,559	Bom
S9VH	SLC	Lee 9x9	VH	0,893	0,785	Muito Bom
S9VV	SLC	Lee 9x9	VV	0,526	0,024	Ruim
S9RC	SLC	Lee 9x9	RC	0,849	0,697	Muito Bom
G3VH	GRD	Lee 3x3	VH	0,866	0,730	Muito Bom
G3VV	GRD	Lee 3x3	VV	0,538	0,040	Ruim
G3RC	GRD	Lee 3x3	RC	0,771	0,532	Bom
G9VH	GRD	Lee 9x9	VH	0,914	0,826	Excelente
G9VV	GRD	Lee 9x9	VV	0,546	0,061	Ruim
G9RC	GRD	Lee 9x9	RC	0,866	0,729	Muito Bom

Fonte: do autor (2023)

Analisando a Figura 4.1, é possível perceber que, de forma geral, os valores de Acurácia do Usuário (AU) são muito próximos entre si quando comparamos para as classes falha e plantada, variando uma média de apenas 4% por cenário. É notório também, a similaridade do comportamento desse gráfico com o de Acurácia Global, os valores observados para a AU variam para mais ou para menos, em média 3% para a classe falha e 1% para a classe de plantio, em comparação com o mesmo cenário da AG. Os cenários que tiveram a maior diferença de AU entre as classes foram o S3RC e o G3RC, onde a AU da classe falha superou a AU da classe plantada em 10 e 11%, respectivamente. É interessante observar que, fazendo a média simples para os valores de acurácia dos 12 cenários, a AG, AU (falha) e AU (plantio) apresentam 75% de acurácia cada.

Já para o gráfico de Acurácia do Produtor (AP), de forma geral, os valores de AP são bem diferentes entre si ao compararmos os valores para as classes falha e plantada, variando cerca de 22% em média por cenário, para mais ou para menos. É fácil perceber também que os valores de AP para a classe falha são em média, 12% menores que os valores de AG para os mesmos cenários. Já para a classe de plantio, os valores de AP são em média 10% maiores que os valores de AG para os mesmos cenários. Os cenários que apresentaram maior divergência de AP para as duas classes foram o S3VV e G3VV, com os valores da classe de plantio foram respectivamente 53 e 55% maiores que os valores de AP da classe falha. Na média geral para os 12 cenários, a AP (falha) foi de 63%, a AG foi de 75% e a AP (plantio) foi de 85%.

Figura 4.1 – Gráfico comparativo com valores de Acurácia Global (AG), Acurácia do Produtor (AP) e Acurácia do Usuário (AU).

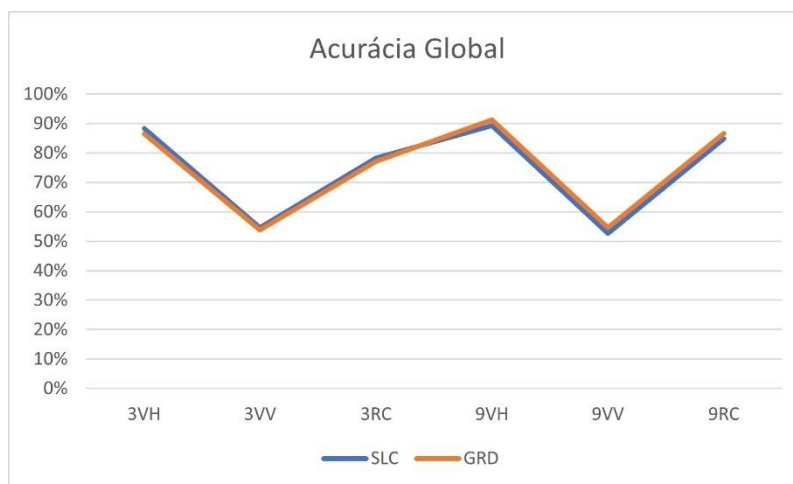


Fonte: do autor (2023)

4.3. SLC x GRD

O comportamento da curva dos valores de acurácia global para as imagens SLC e GRD (Figura 4.2) é muito parecido, as curvas praticamente se sobrepõem, indicando valores muito próximos entre si. Observa-se que as imagens SLC apresentaram em média um desempenho 2% melhor que as imagens GRD para os cenários onde foram combinadas com o Filtro Lee 3x3. Por outro lado, nos cenários combinados com o Filtro Lee com janela 9x9, as imagens GRD apresentaram melhor desempenho, superando as imagens SLC também em 2%. Com isso, a média da AG para os dois tipos de imagens apresentou o mesmo valor, 75%.


Figura 4.2 – Gráfico comparativo entre os valores de Acurácia Global (AG) das imagens SLC e GRD.



Fonte: Do autor (2023).

Em linha com o cenário observado para a AG, os valores de acurácia do produtor e acurácia do usuário também apresentam valores muito próximos entre si para o mesmo cenário e mesma classe, conforme pode ser observado abaixo na Figura 4.3.

Figura 4.3 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das imagens SLC e GRD.



Fonte: do autor (2023)

No gráfico de acurácia do produtor, podemos observar que para a classe plantada, a curva de SLC e GRD é bem similar, com a média das imagens GRD sendo 2% maior que a das imagens SLC, devido ao seu melhor desempenho nos cenários da janela 9x9. Para a classe falha também temos as linhas de GRD e SLC muito semelhantes, com os cenários SLC superando os cenários GRD em 2%, em decorrência de um leve melhor desempenho quando combinados com a polarização RC. O gráfico destoa bastante do gráfico de AG, já que para os cenários com polarização VV, os valores da AP da classe plantadas foram em média 23% maiores que os valores de AG e para a classe de falha, o valor foi em média 27% menores que o valor de AG, chegando a valores abaixo dos 30% de AP. Em média, ambos os tipos de imagens apresentaram 74% de acurácia do produtor.


Já para o gráfico de acurácia do usuário, os valores de AU para os tipos de imagens e para as classes são muito parecidos, com as 4 linhas praticamente se sobrepondo para vários cenários, sendo perceptível também a semelhança com o gráfico da AG. Tanto a média da AU dos cenários do tipo SLC e GRD e dos cenários das classes falha e plantio apresentaram 75%, mesmo valor das médias de AG dos cenários SLC e GRD.

4.4. Filtro Lee 3x3 x Filtro Lee 9x9

A Figura 4.4 mostra o gráfico com o comportamento da curva de acurácia global para os cenários processados com a janela 3x3 e 9x9 do filtro Lee. As linhas para ambas as janelas têm um comportamento parecido ao longo dos cenários, com a linha do filtro Lee 9x9 apresentando valores um pouco mais altos que os da linha do filtro Lee 3x3 para as polarizações VH e RC. A aplicação de uma janela 9x9 do filtro Lee resultou em uma acurácia global média

de 77%, superando em 5% a média de AG obtida com a aplicação da janela 3x3 para os mesmos cenários.


Figura 4.4 – Gráfico comparativo entre os valores de Acurácia Global (AG) das janelas 3x3 e 9x9 do Filtro Lee.



Fonte: do autor (2023)

A Figura 4.5 mostra os gráficos de acurácia do produtor e acurácia do usuário por classe e por janela de filtragem. Observa-se, de maneira geral, que para as polarizações VH e VV as curvas 3x3 e 9x9 são semelhantes tanto para a classe plantada quanto para a classe de falha. Já para a polarização RC, a acurácia do produtor da janela 3x3 da classe falha é em média 19% menor que a média do mesmo cenário da janela 9x9, o que influencia para que a AG da janela 3x3 seja prejudicada, principalmente na polarização RC.

Figura 4.5 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das janelas 3x3 e 9x9 do Filtro Lee.



Fonte: do autor (2023)

Para a classe falha, a acurácia do produtor média é 8% menor para o Filtro Lee 3x3 do que para o 9x9, indicando que nessa janela houve maior omissão dos pixels dessa classe. Para


a classe de plantio, os valores de AP são mais coerentes entre si, apresentando média de 86% de acurácia para a janela 3x3 e 85% para a janela 9x9.

Sobre a acurácia do usuário, podemos observar que as 4 linhas apresentam comportamentos muito semelhantes entre si e comparados com a acurácia global. A janela 9x9 do filtro Lee apresentou uma média de AU de 76%, enquanto a média observada para a janela 3x3 foi de 73%. Foi observado uma média de AU 1% maior para o Filtro Lee 9x9 na classe falha e 5% maior na classe de plantio, em comparação com os mesmos cenários da janela 3x3. Essa diferença é devido aos erros de comissão presentes principalmente no cenário S3RC da classe plantada.

4.5. Polarizações VH x VV x RC

Analisando o gráfico da acurácia global por polarização (Figura 4.6), é possível perceber que as curvas são muito bem definidas, não se cruzando em nenhum momento. A polarização VH apresentou os melhores cenários de AG, os valores variaram entre 87 e 91%, com média de 89%. A posição intermediária ficou com a polarização RC, que apresentou média de 82%, com seus valores de AG variando entre 77 e 87%. A polarização VV obteve o pior desempenho nas classificações, variando seus valores de AG entre 53 e 55% e obtendo uma média de apenas 54% de acurácia global.

Figura 4.6 – Gráfico comparativo entre os valores de Acurácia Global (AG) das polarizações VH, VV e RC.




Fonte: do autor (2023)

Ao analisar o gráfico da acurácia do produtor (Figura 4.7), temos a polarização VH com valores constantes tanto para a classe plantada quanto para a classe de falha, com média de 89%. Para a polarização RC, a classe de plantio apresenta uma média similar à obtida no cenário VH, entretanto, a AP da classe falha ficou na casa dos 60% para os cenários com janela 3x3 do filtro Lee, o que resultou em um valor médio de 81% para essa polarização. A classe de plantio da polarização VV apresentou um bom desempenho, chegando a valores próximos a 80%, por outro lado, os valores de AP para a classe falha não passaram dos 30%. Devido à grande omissão dos pixels dessa classe, o valor médio da acurácia do produtor para a polarização VV atingiu apenas 52%.

Ainda na Figura 4.7, podemos observar que para as polarizações VH e VV, o gráfico da acurácia do usuário para as duas classes possuem valores muito próximos entre si e se assemelha com os valores observados no gráfico de acurácia global, apresentando média de 89 e 83% respectivamente. Ao contrário do ocorrido com a AP, no gráfico da acurácia do usuário é a classe plantada que possui valores 5% menores em média que a classe falha. Essa discrepância ocorre devido à maior porcentagem de erros de comissão para a classe de plantio na polarização RC, que deixou a média desses cenários em 83%.

Figura 4.7 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe das polarizações VH, VV e RC.



Fonte: do autor (2023)

4.6. Cenário com melhor desempenho

O cenário que apresentou o melhor desempenho classificatório foi o cenário G9VH, que se refere à classificação realizada a partir da banda de polarização VH, resultante do processamento da imagem do tipo GRD e aplicação do filtro Lee com uma janela de 9x9. Esse

cenário apresentou uma acurácia global de 91,4% e número Kappa de 0,826, recebendo o conceito de “Excelente” segundo a classificação proposta por Fonseca (2000).

Tabela 4.2 – Matriz de confusão referente ao cenário G9VH.

Classificado	Referência		Total
	Falha	Plantio	
Falha	838	78	916
Plantio	95	989	1084
Total	933	1067	2000

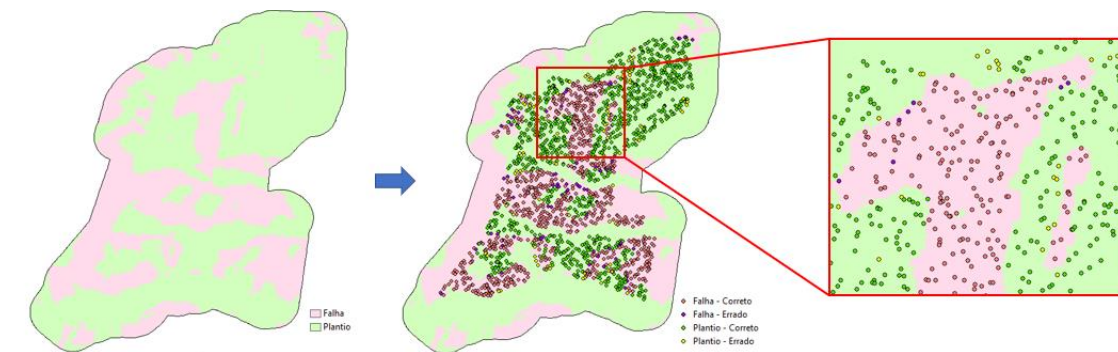
Fonte: do autor (2023)

Ao analisarmos a Tabela 4.2, podemos entender melhor o desempenho classificatório do cenário G9VH. Dos 933 pontos que se referiam à classe falha na imagem de referência, 838 foram classificados corretamente e 95 foram omitidos (erro de omissão de 10,18%), sendo classificados incorretamente como plantio e resultando em uma acurácia do produtor de 89,82%. A acurácia do produtor para a classe plantio atingiu 92,69%, já que dos 1067 pontos referentes à classe plantada de acordo com a imagem de referência, apenas 78 foram classificados incorretamente como falha, resultando em um erro de omissão de 7,31%.

Em relação à classe falha, a acurácia do usuário foi de 91,48%, já que dos 916 pontos classificados como falha no cenário G9VH, 78 eram na verdade plantio (erro de comissão de 8,52%). Já para a classe plantio, 1084 pontos foram classificados como área plantada pelo cenário G9VH, dos quais 95 eram na verdade falhas de plantio, o que resultou em um erro de comissão de 8,76% e consequentemente, em uma acurácia do usuário de 91,24%.

A Figura 4.8 mostra o resultado da classificação para o cenário G9VH e os pontos utilizados na validação e geração da matriz de confusão, os pontos estão classificados em 4 classes: os classificados como falha que realmente são falha (vermelho), os que foram classificados como falha e na verdade são plantio (roxo), os que foram classificados como plantio e realmente são plantio (verde) e os que foram classificados como plantio e na verdade são falha (amarelo).

Figura 4.8 – Classificação do cenário G9VH e pontos de validação.



Fonte: do autor (2023)

4.7. Radar x óptico

A partir do processamento dos dados obtidos do sensor óptico Sentinel-2A (tópico 3.6.2.), classificação e validação (tópico 3.9.), foi computada a matriz de confusão para a imagem NDVI (Tabela 4.3). A classificação NDVI do sensor óptico, que foi realizada com base nos mesmos parâmetros adotados no sistema Monitora, resultou em uma acurácia global de 94,50% e número Kappa de 0,890, o que atribuiu à essa classificação o conceito de “Excelente” de acordo com a classificação proposta por Fonseca (2000).

Tabela 4.3 – Matriz de confusão referente a classificação com o NDVI do Sentinel-2A.

Classificado	Referência		Total
	Falha	Plantio	
Falha	897	74	971
Plantio	36	993	1029
Total	933	1067	2000

Fonte: do autor (2023)

Podemos perceber que o cenário óptico a partir do NDVI classificou corretamente como falha 897 dos 933 pontos de plantio obtidos com a imagem de referência (3,86% de omissão), resultando em uma acurácia do produtor de 96,14%. Para a classe plantada, a classificação NDVI classificou corretamente 993 dos 1067 pontos de plantio da imagem de referência, resultando em 6,94% de erro de omissão e 93,06% de acurácia do produtor.

Sobre os erros de comissão, para a classe de falha 74 dos 971 pontos classificados foram classificados erroneamente, pois na imagem de referência eram plantio, o que resultou em 7,62% de erro e implicando em uma acurácia do usuário de 92,38%. Apenas 36 dos 1036 pontos

classificados como plantio estavam errados em comparação com a classificação de referência, o que resultou em 96,50% de acurácia do usuário e apenas 3,50% de erro de comissão.

A Tabela 4.4 mostra o comparativo entre o desempenho classificatório do melhor cenário obtido com os dados SAR e o desempenho classificatório obtido a partir do NDVI dos dados ópticos do sensor Sentinel-2A.


Tabela 4.4 – Comparação de desempenho classificatório entre os sensores radar e óptico.

Sensor	Cenário	Acurácia do Produtor		Acurácia do Usuário		Acurácia Global	Número Kappa	Desempenho
		Falha	Plantio	Falha	Plantio			
Radar	G9VH	89,82%	92,69%	91,48%	91,24%	91,35%	0,826	Excelente
Óptico	NDVI	96,14%	93,06%	92,38%	96,50%	94,50%	0,890	Excelente

Fonte: do autor (2023)

É possível observar na Tabela 4.4 que as classificações com os dois tipos de sensores obtiveram ótimos desempenhos classificatórios, ambas com acurácia global superior à 90% e conceituadas como “Excelente” de acordo com Fonseca (2000). O desempenho do sensor óptico (Sentinel-2A) apresentou resultados melhores para a distinção entre as classes de plantio e de falha, com uma melhora de 3,15% na acurácia global e de 6,40% para o número Kappa em relação ao mapeamento com o sensor radar (Sentinel-1A).

Figura 4.9 – Gráfico comparativo entre os valores de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) por classe e tipo de sensor.



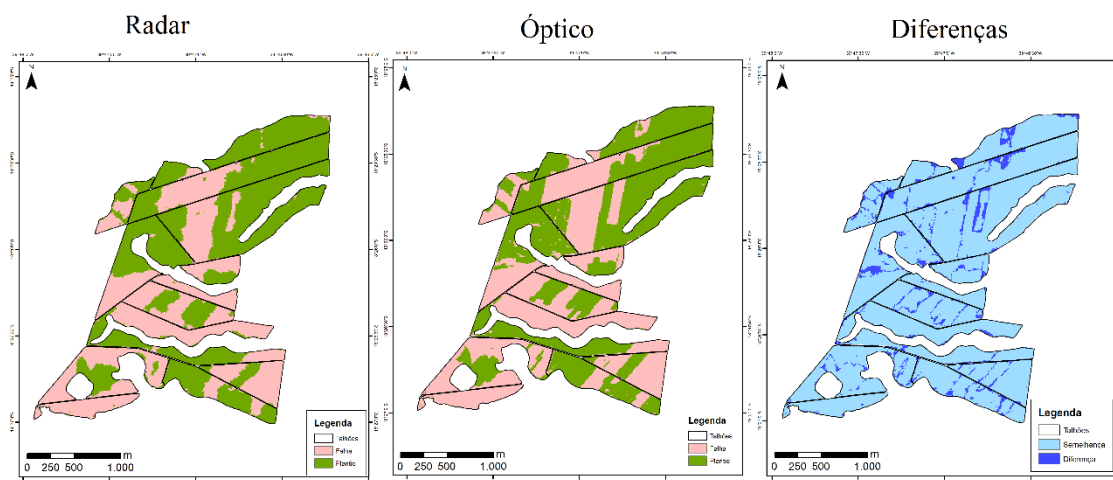
Fonte: do autor (2023)

Ao analisar o gráfico da acurácia do produtor para ambos os sensores (Figura 4.9), podemos perceber que os resultados obtidos com o sensor radar e ópticos foram muito semelhantes, apresentando uma maior diferença na AP da classe falha, onde obtivemos um aumento de 6,32% quando mapeada com o sensor óptico. Já para a classe plantada, o sensor radar apresentou um desempenho apenas 0,37% inferior à AP obtida com o sensor óptico.

Ainda na Figura 4.9, podemos observar o gráfico da acurácia do usuário e perceber um comportamento inverso entre as classes, a classificação com o sensor radar foi apenas 0,9% inferior à classificação com o sensor óptico para a classe de falha, enquanto para a classe de plantio o sensor óptico apresentou uma acurácia do usuário 5,26% superior à obtida com o sensor radar.

A Figura 4.10 mostra o mapa das classificações realizadas com ambos os sensores e a diferença observada entre eles na área de estudo. Dos 2000 pontos validados, 1853 apresentaram classificações iguais entre os sensores e apenas 147 divergiram a classificação entre si, ou seja, houve concordância em 92,65% dos pontos amostrados. Dos 1853 pontos com valores iguais para o sensor óptico e sensor radar, 1785 estavam corretamente classificados de acordo com a imagem de referência, resultando em uma acurácia de 96,33%.

Figura 4.10 – Comparação das classificações realizadas pelo cenário G9RD do radar, NDVI do sensor óptico e mapa com as diferenças entre as classificações.



Fonte: do autor (2023)

Os mapas das duas classificações são muito semelhantes, com as diferenças de classificação ocorrendo principalmente nas áreas de transição entre floresta plantada e falha de plantio.

5. DISCUSSÃO DOS RESULTADOS

5.1. Classificação com coeficiente de retroespalhamento do radar

Analisando os resultados obtidos para as classificações realizadas com os coeficientes de retroespalhamento (σ^0) obtidos através do processamento das cenas do sensor SAR Sentinel-1A, nota-se que o cenário G9VH foi o que apresentou os melhores resultados. Para esse cenário foram utilizadas imagens do tipo GRD (Ground Range Detected), que foram filtradas utilizando

a janela 9x9 do Filtro Lee e classificadas a partir do coeficiente de retroespalhamento da banda de polarização VH.

Ao observar a importância das variáveis testadas e a sua interferência sobre a acurácia global da classificação, percebe-se que a variável polarização exerceu a maior influência no desempenho classificatório, seguida pela variável do tamanho da janela de filtragem aplicada no Filtro Lee. Para a variável do tipo de imagem, a utilização de imagens do tipo GRD ou SLC teve baixa influência no resultado da acurácia global. Essa influência pode ser explicada na Figura 3.11, que mostra a distribuição dos gráficos box-plot para as classes analisadas, onde podemos observar que quando combinadas as variáveis da janela 9x9 do Filtro Lee com a polarização VH, temos distribuições mais bem definidas e sem sobreposição de intervalos entre as classes de plantio e de falha.

Segundo Elachi (1987), menores comprimentos de ondas têm baixa capacidade de penetração nos dosséis. Assim, para sensores como o Sentinel-1A que utilizam a banda C e têm o comprimento de onda mais curto, o coeficiente de retroespalhamento é influenciado, principalmente, pelo retroespalhamento do topo do dossel (LANG et al., 2008). Em relação ao efeito de polarização, Oldoni et al. (2019) relata que a polarização VH é mais sensível à dispersão de volume, enquanto VV é sensível tanto ao espalhamento de superfície como à dispersão de volume, o que explica a dispersão das classes observada nos gráficos box-plot da Figura 3.11, onde para a polarização VH temos valores mais altos para o coeficiente de retroespalhamento da classe plantada e baixos valores para a classe de falha de plantio, que se refere à solo exposto. Ao analisar o coeficiente de retroespalhamento da polarização VH para a detecção de desmatamento, Rodrigues (2018) também observou que houve uma redução significativa nos valores de σ° quando comparavam o σ° da área com vegetação com o σ° da mesma área após o desmatamento. Já para a polarização VV, que neste estudo apresentou o pior desempenho entre as polarizações estudadas, houve uma grande confusão entre as classes no gráfico box-plot, já que essa polarização é sensível tanto ao espalhamento volumétrico da classe de plantio quanto ao espalhamento superficial da classe de falha, resultando em baixos valores de acurácia global.

Diniz (2019) analisou separadamente o comportamento do filtro Lee para diferentes tamanhos de janelas de filtragem e constatou uma diminuição crescente dos valores do coeficiente de variação das janelas de 3x3 a 9x9, indo de encontro ao melhor desempenho dos cenários processados com o filtro Lee 9x9 em relação aos processados com a janela 3x3 neste trabalho. Outro fator que explica o melhor desempenho classificatório da janela 9x9 é que, conforme observado por Medeiros (1999) ao analisar o efeito do tamanho das janelas de

filtragem na relação sinal-ruído das cenas, quanto maior a janela de processamento, maior a relação sinal-ruído, e conseqüentemente menor o speckle presente na cena.

Os resultados referentes à variável do tipo de imagem apresentaram um desempenho muito similar, com diferença de acurácia global de menos de 1%. Isso deve-se ao fato de que ambos os tipos de imagens são produtos de nível 1, com a diferença de que os produtos GRD são dados SAR já processados com *multi-looking* e projetados para o alcance do solo usando um modelo de elipsoide terrestre (ESA, 2023a). Então, com exceção da etapa de *multi-looking* que já havia sido aplicada nos dados GRD e da etapa de *deburst* (já que a imagem GRD é contínua e não tem divisão por bursts), todos os outros processamentos foram realizados para os dois tipos de imagens com os mesmos parâmetros, o que resulta em dados finais com características bem parecidas, como podemos observar nos gráficos box-plot da Figura 3.11 e conseqüentemente nos valores de corte da Tabela 3.3, que apresenta valores de corte muito próximos entre dados GRD e SLC para a mesma janela de filtragem e mesma polarização.

5.2. Comparação entre radar e óptico

Por meio da comparação entre as classificações realizados pelos sensores radar (Sentinel-1A, cenário G9VH) e óptico (Sentinel-2B, NDVI), obtivemos pouca diferença entre os valores de acurácia global, com o sensor óptico apresentando valores 3,15% maiores. Conforme podemos observar na Tabela 4.4, tivemos maiores diferenças entre os sensores na acurácia do produtor da classe falha e na acurácia do usuário da classe plantada, com valores de 6,32% e 5,26% maiores para o sensor óptico, respectivamente. Diniz (2019) também observou uma baixa diferença nos valores de acurácia global (4,33%) entre as classificações de uso e cobertura do solo na região de Ariquemes-RO obtidas com sensor óptico Sentinel-2B e sensor radar Sentinel-1A classificado pelo classificador Random Forest.

Apesar da classificação com o sensor óptico ter apresentado resultados um pouco melhores que a classificação com o sensor SAR, vale a pena destacar a limitação enfrentada na utilização deste tipo de sensor, como por exemplo a cobertura de nuvens. Por isso, a utilização de imagens ópticas é menor em regiões tropicais, onde existe cobertura quase que permanente de nuvens durante o ano (EVANS; COSTA, 2013). Asner (2001) e Leinenkugel et al. (2014) também destacam sobre a dificuldade de obter cenas ópticas sem a presença de nuvens. Para a região de estudo, por exemplo, que é caracterizada por apresentar um clima tropical chuvoso sem estação seca no inverno, segundo a classificação de Köppen (ALVARES et al, 2013),

muitas vezes enfrentamos janelas de alguns meses sem obtenção de imagens ópticas para determinadas áreas.

Os sensores SAR Sentinel-1A possui dados gratuitos que são disponibilizados pela Agência Espacial Europeia (ESA), com uma resolução temporal de 10 dias sem a interferência da cobertura de nuvens. Apesar de apresentarem algumas limitações como o baixo comprimento de onda e conseqüentemente uma baixa penetração no dossel das áreas florestais e apresentar apenas duas polarizações (VH e VV), apresentou resultados satisfatórios na distinção entre as classes de plantio e falha neste estudo. Segundo Silva et al. (2019), a tecnologia SAR mostrou-se útil na identificação dos desmatamentos, principalmente durante o período de chuvas na região amazônica.

6. CONCLUSÕES E CONSIDERAÇÕES FINAIS

O desempenho classificatório dos coeficientes de retroespalhamento foram obtidos a partir da construção de diferentes cenários com os dados de radar do sensor Sentinel-1A. Foi possível observar que a combinação entre diferentes polarizações e janelas de filtro implicaram em grande influência nos valores de acurácia global e número Kappa para os cenários propostos, já a variável do tipo de imagem exerceu uma baixa influência nesses mesmos valores.

O cenário G9VH foi o que obteve o melhor desempenho classificatório, de modo geral, sendo capazes distinguir as classes de floresta de eucalipto e falhas de plantio, apresentando valores de acurácia global e número Kappa considerados excelentes. Esse cenário utilizou as variáveis VH e 9x9, que foram a polarização e a janela de filtragem do filtro Lee que apresentaram melhor desempenho de acurácia global, respectivamente. Esse cenário utilizou também a variável GRD como tipo imagem, que apesar de não ter diferença no desempenho classificatório quando comparada com os cenários das imagens do tipo SLC, são dados que possuem um nível de pré-processamento que diminui a demanda computacional e preserva a resolução espacial, por já serem processados com *multi-looking* e projetados para o alcance do solo.

Apesar de apresentar um desempenho um pouco inferior quando comparado com a classificação a partir de dados ópticos, o melhor cenário obtido com os dados de radar apresentou um desempenho considerado satisfatório na detecção de falhas de plantio, sendo capaz de identificar a maior parte das áreas de falhas e ter baixa ocorrência de falsos positivos. As imagens do sensor SAR Sentinel-1 podem ser utilizadas para mapeamento e detecção de

falhas de plantios em florestas de eucalipto tanto na ausência de imagens ópticas quanto em conjunto com elas, visando diminuir o intervalo entre monitoramentos de uma mesma área.

Além disso, o sensor de radar não sofre interferência das nuvens, que é um dos principais problemas da detecção de falhas com sensores ópticos, que implicam em longos períodos sem imagens para monitorar determinadas áreas e alta ocorrência de falsos alertas de falhas de plantios, já que pixels de nuvem que não são detectados pelo filtro de nuvem são apontados como falha de plantio. Vale ressaltar que a garantia da continuidade na disponibilização de imagens SAR do sensor Sentinel-1 é imprescindível para instigar o investimento e aprofundamento nos estudos para ampliar o leque de utilização dessas imagens no setor florestal.

Para futuros estudos, sugere-se a avaliação do comportamento dos valores de corte da classificação para diferentes regiões do Brasil e diferentes épocas do ano, para entender se há diferença na distribuição e nos valores dos pixels das classes de plantio e de falha, assim permitindo a padronização dos valores de corte para uma detecção automática de falhas de plantio, assim como já acontece no sistema Monitora para os sensores Sentinel-2 e Landsat. Além disso, sugere-se também a avaliação do uso conjunto do sensor de radar com o sensor óptico, buscando uma maior acurácia na classificação e diminuição dos falsos positivos para falhas de plantio devido à ocorrência de pixels de nuvem não filtrados.

Referências bibliográficas

ADENIYI, Peter O. Digital analysis of multitemporal Landsat data for land-use/land-cover classification in a semi-arid area of Nigeria. **Photogrammetric engineering and remote sensing**, v. 51, n. 11, p. 1761-1774, 1985.

ALVARES, Clayton Alcarde et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

AGGARWAL, Shefali. Principles of remote sensing. **Satellite remote sensing and GIS applications in agricultural meteorology**, v. 23, n. 2, p. 23-28, 2004.

ALLEN, W. A.; RICHARDSON, A. J.. Interaction of Light with a Plant Canopy. *Journal Of The Optical Society Of America*. Washington., p. 1023-1028. 1968.

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.

BENEDITTI, Cristina Aparecida. **Imagens multitemporais ALOS/PALSAR baseada em orientação a objeto na discriminação da cobertura da terra**. 2010.

BEZERRA, Diego Xavier. DETECÇÃO DE ALVOS MARÍTIMOS A PARTIR DE DADOS SENTINEL-1 EM REGIÃO OCEÂNICA ADJACENTE AO NORDESTE DO BRASIL. **CEP**, v. 12, p. 010, 2021.

BINS, L.S.; ERTHAL, G.J.; FONSECA, L.M.G. **Um método de classificação não supervisionada por regiões**. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, 6., 1993, Recife. Anais do SIBGRAPI93. Recife: SBC/UFPE, 1993. v.2, p.65-68.

BRITES, Ricardo Seixas; SOARES, Vicente Paulo; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 8, 1996.

CAPELA, Marisa Veiga; CAPELA, Jorge MV. Elaboração de gráficos box-plot em planilhas de cálculo. In: **congresso de matemática aplicada e computacional da região sudeste-cnmac Sudeste**. 2011.

CHAMPION, Isabelle et al. Effect of forest thinning on the radar backscattering coefficient at L-band. **International Journal of Remote Sensing**, v. 19, n. 11, p. 2233-2238, 1998.

CHUVIECO, E. Fundamentos de teledetection espacial. **Madrid: Unigraf**, 1990.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.

CONGALTON, R.G. **A review of assessing the accuracy classificatons of remotely sensed data**. *Remote Sensing Environment*, v. 37, p.35-46, 1991.

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

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. [S.l.]: CRC Press, 2009.

COOPS, Nicholas C. Eucalypt forest structure and synthetic aperture radar backscatter: a theoretical analysis. **Trees**, v. 16, n. 1, p. 28-46, 2002.

CORREIA, Igor Bispo de Moraes Coelho. Detecção de desmatamento em imagens de SAR usando redes neurais profundas. 2021.

COUTO, H. T. Z. Sistemas Integrados de Levantamentos Florestais. In: SIMPÓSIO SOBRE INVENTÁRIO FLORESTAL, 2. 1984. Piracicaba. Anais. Piracicaba: IPEF, 1984, 131p.

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

CROSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1993.

DASSAN, Marcos Augusto Ananias et al. Construção de uma série temporal de NDVI com o produto HLS, para detecção de desfolha em Eucaliptos. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**. INPE, Santos, São Paulo. URL: <https://proceedings.science/sbsr-2019/papers/construcaode-uma-serie-temporal-de-ndvi-com-o-produtohls--para-deteccao-de-desfolha-em-eucaliptos>. Acesso, v. 24, p. 2021, 2019.

DENIZE, Julien; HUBERT-MOY, Laurence; POTTIER, Eric. Polarimetric SAR time-series for identification of winter land use. **Sensors**, v. 19, n. 24, p. 5574, 2019.

DINIZ, J. M. **Avaliação do Potencial Dos Dados Polarimétricos Sentinel-1A Para Mapeamento Do Uso e Cobertura da Terra na Região de Ariquemes (RO)**. 2019. Tese de Doutorado. Instituto Nacional de Pesquisas Espaciais (INPE).

DONG, Y.; MILNE, A. K.; FORSTER, B. C. Toward edge sharpening: A SAR speckle filtering algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 4, p. 851-863, 2001.

DUTRA, Luciano Vieira et al. Processamento de imagens de radar de abertura sintética—princípios e aplicações. In: **Anais do iv workshop em tratamento de imagens, npdi/dcc/icex/ufmg**. 2003.

Elachi, C. **Introduction to Physics and Techniques of Remote Sensing** New York. Wiley & Sons , 1987.

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.

ESRI. **Composite Bands function-Help | ArcGIS for Desktop**. 2016. Disponível em: <<https://desktop.arcgis.com/en/arcmap/10.3/manage-data/raster-and-images/composite-bands-function.htm#:~:text=The%20Composite%20Bands%20function%20allows>>. Acesso em: 2 fev. 2023.

ESRI. **Create Pan-sharpened Raster Dataset**. 2021a. Disponível em: <
<https://desktop.arcgis.com/en/arcmap/latest/tools/data-management-toolbox/create-pansharpened-raster-dataset.htm> >. Acesso em: 2 fev. 2023.

ESRI. **Raster Calculator**. 2021b. Disponível em: <
<https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/raster-calculator.htm> >. Acesso em: 2 fev. 2023.

EUROPEAN SPACE AGENCY. **Ride into orbit secured for Sentinel-1C**. 2022. Disponível em: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1/Ride_into_orbit_secured_for_Sentinel-1C. Acesso em: 07 mar. 2023.

EUROPEAN SPACE AGENCY. **Sentinel-1 SAR technical guide**. 2023a. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar>. Acesso em: 16 jan. 2023.

EUROPEAN SPACE AGENCY. **Sentinel-2 MSI introduction**. 2023b. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>. Acesso em: 22 jan. 2023.

EVANS, T.L.; COSTA, M. Landcover classification of the lower Nhecolândia subregion of the Brazilian Pantanal wetlands using ALOS/PALSAR, RADARSAT-2 and ENVISAT/ASAR imagery. **Remote Sensing of Environment**, v.128, p.118– 137, 2013.

FIDALGO, E. C.C. **Exatidão no processo de mapeamento temático da vegetação de uma área de mata atlântica no estado de São Paulo, a partir de imagens TM-Landsat**. 1995. 186p. (INPE-5944-TDI/570). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995.

FILIPPONI, Federico. Sentinel-1 GRD preprocessing workflow. **Multidisciplinary digital publishing institute proceedings**, v. 18, n. 1, p. 11, 2019.

FLORENZANO, Teresa Galotti. **Iniciação em Sensoriamento Remoto**. 3. ed. São Paulo: Oficina de Textos, 2011. 128 p.

EPIPHANIO, J.C.N. et al. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa agropecuária brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.

FONSECA, L. M. G. **Processamento digital de imagens**. Instituto Nacional de Pesquisas Espaciais (INPE), 2000.

GAMA, Fábio Furlan; DOS SANTOS, João Roberto; MURA, José Claudio. Continuous monitoring of biophysical Eucalyptus sp. parameters using interferometric synthetic aperture radar data in P and X bands. **Journal of Applied Remote Sensing**, v. 10, n. 2, p. 026002-026002, 2016.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: **Edgard Blücher**, 2000. Tradução de Roberto Marcondes Cesar Junior; Luciano da Fontoura Costa.

GUERRA, J. B. et al. Discriminating deforestation increment areas in the Amazon rainforest with L band SAR R99B data. **Acta Amazonica**, v.40, n.3, p.557-566, 2010.

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.

IBÁ - Indústria Brasileira de Árvores. **Relatório Anual Ibá 2021**. São Paulo: Café Art, 2021. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorioiba2021-compactado.pdf>. Acesso em: agosto de 2022.

INCAPER - INSTITUTO CAPIXABA DE PESQUISA ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL. Conceição da Barra. Disponível em: https://incaper.es.gov.br/media/incaper/proater/municipios/Conceicao_da_Barra.pdf. Acesso em 21 de janeiro de 2023

INCAPER - INSTITUTO CAPIXABA DE PESQUISA ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL. Mapas de chuva – Normal Climatológica. Disponível em: <https://meteorologia.incaper.es.gov.br/mapas-de-chuva-normal-climatologica>. Acesso em: 21 de janeiro, 2023

INCAPER - INSTITUTO CAPIXABA DE PESQUISA ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL. Mapas de temperatura – Normal Climatológica. Disponível em: <https://meteorologia.incaper.es.gov.br/mapas-de-temperatura-normal-climatologica>. Acesso em: 21 de janeiro, 2023

JENSEN, J.R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 1 ed. São José dos Campos: Parêntese; 2009. 604 p.

JOSHI, N. et al. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, v. 8, n. 70, p. 23, 2016.

JUNIOR, Wirth Lima. Ondas Eletromagnéticas; Guias de Ondas Planares constituídos por Dielétricos; Ondas Superficiais em Lâminas Dielétricas, 2020.

KASISCHKE, E. S. et al. **The use of imaging radars for ecological applications: a review**. **Remote Sensing of Environment**, v.57, n. 2, p. 141-156, 1997.

KIM, J. S.; LEE, H. D.; KIM, B. **Coherence adaptive speckle filter for ultrasound image**. 2007. 9th International Symposium on Signal Processing and Its Applications, Sharjah, p. 1-4, 12-15 fev. 2007.

LANG, Megan W.; KASISCHKE, Eric S. Using C-band synthetic aperture radar data to monitor forested wetland hydrology in Maryland's coastal plain, USA. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 2, p. 535-546, 2008.

LEE, J. et al. Speckle reduction in multipolarization, multifrequency SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v.29, n. 4, p.535-544,1991.

LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-2, n. 2, 1980.

LEE, Jong Sen; POTTIER, Eric. Polarimetric radar imaging: from basics to applications. 2009. **Optical Science and Engineering**, 2009.

LEINENKUGEL, Patrick et al. Sensitivity analysis for predicting continuous fields of

tree-cover and fractional land-cover distributions in cloud-prone areas. **International Journal of Remote Sensing**, v. 35, n. 8, p. 2799-2821, 2014.

LEWIS, A. J. et al. W. Radar fundamentals: the geoscience perspective. In: LEWIS, A.J.; HENDERSON, F. M.; RYERSON, R. A. (Eds.). **Principles and applications of imaging radar: manual of remote sensing**. 3.ed. New York: John Wiley & Sons, 1998. v.2, cap. 5, p. 271-356.

LIESENBERG, Veraldo; DE SOUZA FILHO, Carlos Roberto; GLOAGUEN, Richard. Evaluating moisture and geometry effects on L-band SAR classification performance over a tropical rain forest environment. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5357-5368, 2016.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and image interpretation**. New York: John Wiley & Sons, 2004. 763p.

LOEBMANN, DG dos SW; VICENTE, Luiz Eduardo; VICTORIA, D. de C. Adaptação do método Fmask para detecção de nuvens em regiões tropicais. In: **Embrapa Territorial-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015., 2015.

LOPES, A.; TOUZI, R.; NEZRY, E. Adaptative speckle filter and scene heterogeneity. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 6, p. 992- 1000, 1990.

MACEDO, R.C. **Prognose madeireira de plantio clonal de Eucalyptus spp. Através de dados derivados de LiDAR aerotransportado**. 2009. 133p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais – Ministério da Ciência e Tecnologia. São José dos Campos, 2009.

MACHADO, Adalberto Pereira. **Polarização de ondas eletromagnéticas**. 2008.

MANDAL, Dipankar et al. Dual polarimetric radar vegetation index for crop growth monitoring using sentinel-1 SAR data. **Remote Sensing of Environment**, v. 247, p. 111954, 2020.

MANDAL, Dipankar et al. Sentinel-1 SLC preprocessing workflow for polarimetric applications: A generic practice for generating dual-pol covariance matrix elements in SNAP S-1 toolbox. 2019.

MAROCO, João. **Análise estatística com utilização do SPSS**. 2007.

MARTINS, Flora da Silva Ramos Vieira et al. Sensitivity of ALOS/PALSAR imagery to forest degradation by fire in northern Amazon. **International Journal of Applied Earth Observation and Geoinformation**, v. 49, p. 163-174, 2016.

MATHER, P. M. **Computer processing of remotely sensed images: an introduction**. 2. ed. Chichester: John Wiley & Sons, 1999. 292 p.

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

- MCNAIRN, H.; BRISCO, B. The application of C-band polarimetric SAR for agriculture: A review. **Canadian Journal of Remote Sensing**, v. 30, n. 3, p. 525-542, 2004.
- MEDEIROS, Fátima Nelsizeuma Sombra de. **Filtragem adaptativa de imagens de radar de abertura sintética utilizando a abordagem maximum a posteriori**. 1999. Tese de Doutorado. Universidade de São Paulo.
- MENESES, Paulo Roberto; ALMEIDA, T. de. Introdução ao processamento de imagens de sensoriamento remoto. **Universidade de Brasília, Brasília**, 2012.
- MORAN, M. Susan; INOUE, Yoshio; BARNES, E. M. Opportunities and limitations for image-based remote sensing in precision crop management. **Remote sensing of Environment**, v. 61, n. 3, p. 319-346, 1997.
- NARAYANAN, S. Kalaivani; WAHIDABANU, R. S. D. A view on despeckling in ultrasound imaging. **International Journal of Signal Processing, Image Processing and Pattern Recognition**, v. 2, n. 3, p. 85-98, 2009.
- NETO, José Valladares et al. Boxplot: um recurso gráfico para a análise e interpretação de dados quantitativos. **Revista Odontológica do Brasil Central**, v. 26, n. 76, 2017.
- NOERNBERG, Mauricio Almeida; DE MORAES NOVO, Evlyn ML; KRUG, Thelma. Aplicação de sistemas radar no monitoramento de infestações de plantas aquáticas em reservatórios: vantagens e limitações. **Bulletin of Geodetic Sciences**, v. 5, n. 1, 1999.
- NOVO, E. M. L. M.; COSTA, M. P. F. Fundamentos e aplicações de radar no estudo de áreas alagáveis. **Oceanografia por satélites. São José dos Campos: Oficina de Textos**, p. 236-258, 2005.
- NOVO, E. M. L. M. Sensoriamento Remoto: princípios e aplicações. 4ª edição. **São Paulo: Edgard Blücher**, 2010.
- OLDONI, L. V. et al. CARACTERIZAÇÃO DA DINÂMICA DA SOJA, MILHO E ALGODÃO COM BASE EM DADOS SAR POLARIMÉTRICOS DO SENTINEL-1A. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto. P692-695, 2019.
- OLDONI, L. V. et al. POLARIMETRIC SAR DATA FROM SENTINEL-1A APPLIED TO EARLY CROP CLASSIFICATION. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 43, 2020.
- PARK, Jeong-Won et al. Efficient thermal noise removal for Sentinel-1 TOPSAR cross-polarization channel. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 3, p. 1555-1565, 2017.
- PÉLLICO NETTO, S. e BRENA, D.A. Inventário Florestal. V.1, Curitiba, PR, 1997.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto na vegetação**. 2. ed. atualizada e ampliada. São Paulo: Oficina de Textos, 2012.
- PERROCA, Márcia Galan; GAIDZINSKI, Raquel Rapone. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes: coeficiente Kappa. **Revista da Escola de Enfermagem da USP**, v. 37, p. 72-80, 2003.

QGIS Development Team. **QGIS Geographic Information System**. 2023a. Disponível em <<http://qgis.org>>. Acesso em: 2 fev. 2023.

QGIS Documentation. **25.2.3. Raster extraction**. 2023b. Disponível em: <https://docs.qgis.org/3.22/en/docs/user_manual/processing_algs/gdal/rasterextraction.html#gdalcliprasterbymasklayer>. Acesso em: 3 fev. 2023.

QGIS Documentation. **25.1.11. Raster analysis**. 2023c. Disponível em: <https://docs.qgis.org/3.22/en/docs/user_manual/processing_algs/qgis/rasteranalysis.html#qgisrasterlayeruniquevaluesreport>. Acesso em: 3 fev. 2023.

RANEY, R. Keith. Radar fundamentals: technical perspective. **Principals and Applications of Imaging Radar, Manual of Remote Sensing**, v. 2, p. 9-130, 1998.

RENNÓ, Camilo Daleles. Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens sir-c/x-sar do perímetro irrigado de bebedouro, petrolina-pe. **São José dos Campos. 73p. Dissertação (Mestrado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais**, 1995.

RICHARDS, J.A. **Remote sensing digital images analysis: an introduction**. Berlin: Springer- Verlag, 1986.281 p.

RICHARDS, J. A. et al. **Remote sensing with imaging radar**. Berlin/Heidelberg, Germany: Springer, 2009.

RODRIGUES, Thaise da Silva. **Detecção de desmatamentos no oeste da Bahia com dados de radar (Sentinel-1A) utilizando a plataforma Google Earth Engine**. 2018.

RODRIGUES, Thaise et al. **Detecção de mudanças na cobertura vegetal natural do Cerrado por meio de dados de radar (Sentinel-1A)**. v. 31, p. 1-22, 2019.

ROUSE J. W.; HAAS, R. H; SCHELL, J. A; DEERING D. W. **Monitoring vegetation systems in the Great Plains with ETRS**. In: Third ETRS Symposium, NASA SP353, Washington, DC. 1:309- 317. 1973.

SANT'ANNA, S.J.S.; MASCARENHAS, N.D.A. Comparação do desempenho de filtros redutores de "Speckle". In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador, BA. **Anais...** São José dos Campos: INPE, 1996. p. 871-877. Disponível em: <<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.01.15.54/doc/T122.pdf>>. Acesso em: 12 jan. 2023.

SANT'ANNA, SIDNEI JS. **Avaliação Comparativa da Perda de Resolução Espacial de Filtros Redutores de Ruído "Speckle"**. 1994.

SCOLFORO, J. R. S. **Modelagem do crescimento e da produção de florestas plantadas e nativas**. Lavras: Universidade Federal de Lavras, 1998. 463p.

SEAMA. Secretaria Estadual de Meio Ambiente e Recursos Hídricos. Atlas da Mata Atlântica do Estado do Espírito Santo 2007 – 2008 / 2012 – 2015. Cariacica – ES: IEMA, 2018. Disponível em: <https://seama.es.gov.br/Media/seama/Principal/Atlas-Mata-Atlantica-ES.pdf>. Acesso em 21 de janeiro de 2023.

- SHI, Z.; FUNG, K. B. A. Comparison of digital speckle filters. **International Geoscience and Remote Sensing Symposium**, Pasadena, v.4, p.2129-2133, 1994.
- SILVA, Claudia Arantes et al. **Análise qualitativa do desmatamento na Floresta Amazônica a partir de sensores SAR, óptico e termal**. 2019.
- SPOT Imagery User Guide**. [s.l: s.n.]. Disponível em: <http://www.engesat.com.br/wp-content/uploads/SPOT6-7_UserGuide_201906.pdf>. Acesso em: 23 jan. 2023.
- STORY, Michael; CONGALTON, Russell G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and remote sensing**, v. 52, n. 3, p. 397-399, 1986.
- TEILLET, P. M.; STAENZ, K.; WILLIAM, D. J. Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions. **Remote Sensing of Environment**, v. 61, n. 1, p. 139-149, 1997.
- TEIXEIRA, Gregório Luiz Galvão; CHACALTANA, Julio Tomas Aquije; ACUÑA, Joel Rojas. Análise da distribuição da temperatura superficial do mar ao largo do estado do Espírito Santo–BR, durante o inverno de 1997. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 14, p. 6673-6680, 2009.
- TOWNSEND, P. A. Relationships between forest structure and the detection of flood inundation in forested wetlands using C-band SAR. **International Journal of Remote Sensing**, v. 23, n. 3, p. 443-460, 2002.
- TUCKER, Ch J. et al. Monitoring corn and soybean crop development with hand-held radiometer spectral data. **Remote Sensing of Environment**, v. 8, n. 3, p. 237-248, 1979.
- ULABY, F.T.; DOBSON, M.C. **Handbook of radar scattering statistics for terrain**. Norwood, Artech House, 1989.
- ULABY, F. T., MOORE, R. K., & FUNG, A. K. **Microwave remote sensing: active and passive. From theory to applications**, Vol. 3. Boston, London: Artech House 1098 pp. 1986.
- VELOSO, Amanda et al. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote sensing of environment**, v. 199, p. 415-426, 2017.
- WANG, Y.; IMHOFF, M. L. Simulated and observed L-HH radar backscatter from tropical mangrove forests. **International Journal of Remote Sensing**, v. 14, n. 15, p. 2819-2828, 1993.
- WEGMULLER, Urs. Automated terrain corrected SAR geocoding. In: **IEEE 1999 International Geoscience and Remote Sensing Symposium. IGARSS'99 (Cat. No. 99CH36293)**. IEEE, 1999. p. 1712-1714.
- WULDER, Michael A. et al. Virtual constellations for global terrestrial monitoring. **Remote Sensing of Environment**, v. 170, p. 62-76, 2015.