



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

LEON MULLER MARQUES

**DETECÇÃO REMOTA DE COLHEITA DE FLORESTAS DE EUCALYPTUS:
UMA ABORDAGEM COM DADOS SENTINEL-2 NO ESTADO DO ESPÍRITO
SANTO**

JERÔNIMO MONTEIRO – ES
2023

LEON MULLER MARQUES

**METODOLOGIA PARA DETECÇÃO DE COLHEITA DE EUCALYPTUS NO
ESPÍRITO SANTO: UMA ABORDAGEM COM SENTINEL-2.**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.
Orientador: Dr. Adriano Ribeiro de Mendonça

JERÔNIMO MONTEIRO – ES

2023

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

M357d Marques, Leon Muller, 1995-
Detecção remota de colheita de florestas de Eucalyptus: uma abordagem com dados sentinel-2 no estado do Espírito Santo / Leon Muller Marques. - 2023.
64 f. : il.

Orientador: Adriano Ribeiro de Mendonça.
Dissertação (Mestrado em Ciências Florestais) -
Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Eucalipto. 2. Sensoriamento Remoto. 3. Cobertura dos solos. 4. Madeira - Exploração. I. de Mendonça, Adriano Ribeiro. II. Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e Engenharias. III. Título.

CDU: 630

DETECÇÃO REMOTA DE COLHEITA DE EUCALYPTUS: UMA ABORDAGEM COM DADOS SENTINEL-2 NO ESTADO DO ESPÍRITO SANTO

Leon Muller Marques

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 31 de outubro de 2023.



Documento assinado digitalmente
CARLOS ANTONIO OLIVEIRA VIEIRA
Data: 01/11/2023 18:10:00-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. Carlos Antonio Oliveira Vieira (Examinador externo)
Universidade Federal de Santa Catarina



Documento assinado digitalmente
ANDRE QUINTAO DE ALMEIDA
Data: 06/11/2023 08:37:01-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. André Quintão de Almeida (Examinador externo)
Universidade Federal de Sergipe



Documento assinado digitalmente
JEANGELIS SILVA SANTOS
Data: 02/11/2023 09:30:00-0300
Verifique em <https://validar.it.gov.br>

Dr. Jeangelis Silva Santos (Examinador externo)
Instituto de Defesa Agropecuária e Florestal do Espírito Santo



Documento assinado digitalmente
ADRIANO RIBEIRO DE MENDONÇA
Data: 06/11/2023 08:49:35-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. Adriano Ribeiro de Mendonça (Orientador)
Universidade Federal do Espírito Santo

Dedico

A todos que sonham com um horizonte, onde
podemos viver num mundo sem exploração.

AGRADECIMENTOS

Quero expressar minha sincera gratidão a todas as pessoas que tornaram possível a conclusão desta dissertação. Em primeiro lugar, gostaria de agradecer ao meu estimado orientador, Adriano, pela orientação, sabedoria e apoio inestimável que ele proporcionou ao longo desta jornada acadêmica. Seu conhecimento e orientação foram fundamentais para o sucesso deste trabalho.

Um agradecimento especial é devido a alguém que começou como um colega de trabalho, mas ao longo dos anos se transformou em um amigo inestimável e uma figura que admiro profundamente: Fabio. Fabio merece minha gratidão por sua constante orientação, apoio e encorajamento ao longo desta jornada acadêmica.

Gostaria também de expressar meu agradecimento a Bruno, que me orientou em diversas ocasiões, iluminando caminhos, especialmente quando me encontrava em becos sem saída, e me reconduzindo à trajetória da ciência.

Gostaria de destacar também o apoio fundamental de Leonardo, um grande amigo que, embora não tenha experiência no campo do sensoriamento remoto ou da área florestal, dedicou seu tempo para ler meus textos e me apoiou em momentos críticos. A sua amizade e contribuições foram inestimáveis.

Além disso, quero expressar minha gratidão a Lucas, que me acolheu quando precisei residir em Jerônimo Monteiro e me apoiou desde o início do mestrado até o seu desfecho.

À minha família, meus pais, quero expressar minha profunda gratidão por seu amor incondicional, apoio financeiro e incentivo contínuo ao longo dos anos. Sem o apoio de vocês, esta conquista não teria sido possível.

Por último, mas definitivamente não menos importante, quero agradecer à minha amada companheira, Fernanda. Sua paciência, compreensão e apoio emocional foram fundamentais durante os momentos desafiadores deste percurso acadêmico. Sua presença em minha vida trouxe equilíbrio e motivação, e por isso sou eternamente grato.

Todos vocês desempenharam papéis cruciais na minha jornada acadêmica e no desenvolvimento deste trabalho. Suas contribuições e apoio foram verdadeiramente inestimáveis. Muito obrigado por estarem ao meu lado e por serem fontes de inspiração. Esta conquista é, em grande parte, devida a vocês.

MARQUES, Leon Muller. **Metodologia para detecção de colheita de *Eucalyptus* no Espírito Santo: uma abordagem com dados Sentinel-2**. 2023. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Adriano Ribeiro de Mendonça.

RESUMO

O setor público necessita de ferramentas que possibilitem um acompanhamento sistemático das áreas de florestas cultivadas. O uso de técnicas de detecção remota viabiliza a vigilância em larga escala por parte dos órgãos ambientais. O objetivo principal deste estudo foi criar uma metodologia para identificar a colheita dos talhões de *Eucalyptus* no estado do Espírito Santo. Para realizar esse monitoramento, utilizou-se a base de dados dos talhões de *Eucalyptus* fornecida por uma empresa. Essa base foi elaborada a partir da análise visual das imagens do Sentinel-2 do ano de 2020. A acurácia do mapa foi validada por meio do coeficiente Kappa. O dado de referência para a colheita também foi obtido por interpretação visual, analisando um histórico de cinco anos de imagens do Sentinel-2. Em cada ano, foram selecionadas as melhores imagens do trimestre, identificando a mudança na resposta espectral da imagem de floresta para solo exposto, indicando a colheita. Na construção do algoritmo de detecção da colheita foram utilizadas as classes de cobertura da terra fornecidas pela Agência Espacial Europeia (ESA), entre os anos de 2019 e 2020, utilizando a classificação de cena (SCL). Esse produto oferece a cobertura da terra para cada imagem do Sentinel-2 coletada a cada cinco dias. Posteriormente, foram filtradas as classes de interesse (nuvem, solo e vegetação). Para obter uma imagem com menor presença de nuvens, foram analisadas três categorias temporais (mensal, bimestral e trimestral), geradas pela agregação das imagens semanais. As classes SCL foram cruzadas com os de talhões de *Eucalyptus*, determinando em qual categoria a base de talhões apresentava menor quantidade de nuvem. Uma vez definida a melhor categoria temporal, a detecção da colheita baseou-se na acumulação dos pixels classificados como solo em cada nova composição de imagem, avaliando a porcentagem de solo no talhão. Experimentações foram realizadas para definir o melhor limite de porcentagem de solo para considerar o talhão como colhido. Para calcular a precisão do algoritmo, foram realizadas avaliações de desempenho com duas estratégias distintas. Estratégia 1 comparou o mês de colheita identificado pelo algoritmo diretamente com a data de referência para cada talhão de *Eucalyptus*. A estratégia 2 comparou o acerto do algoritmo variando um mês antes e um mês depois da data de referência. Em seguida, foi analisado o impacto da declividade e do tamanho do talhão na precisão do algoritmo, calculando os erros e acertos para cada classe de declividade e tamanho de talhão. O mapa de *Eucalyptus* obteve um Kappa de 0,851 e uma precisão global de 94%. A categoria temporal trimestral mostrou-se a mais eficaz para minimizar o efeito das nuvens, já que nenhum talhão apresentou mais de 20% de cobertura por nuvens. A estratégia 2 foi a mais eficiente, atingindo uma precisão do algoritmo de 84,5% com um limiar de 25% de solo. Constatou-se que quanto maior a declividade, menor a precisão, enquanto o tamanho do talhão apresentou uma relação direta, ou seja, quanto maior o tamanho, maior a precisão. O algoritmo desenvolvido representa um avanço na aplicação de novos métodos de monitoramento e fiscalização de plantações de *Eucalyptus*, podendo ser adotado pelo setor público.

Palavras-chave: eucalipto; sensoriamento remoto; cobertura do solo; floresta plantada.

MARQUES, Leon Muller. **METHODOLOGY FOR DETECTION OF EUCALYPTUS HARVEST IN ESPÍRITO SANTO: AN APPROACH WITH SENTINEL-2**. 2023. Master's thesis in Forest Sciences – Federal University of Espírito Santo., Jerônimo Monteiro, ES. orientador: Prof. Dr. Adriano Ribeiro de Mendonça.

ABSTRACT

The public sector requires tools enabling systematic monitoring of cultivated forest areas. The use of remote sensing techniques facilitates large-scale surveillance by environmental agencies. The primary aim of this study was to create a methodology for identifying Eucalyptus stands' harvesting in the state of Espírito Santo. To conduct this monitoring, the Eucalyptus stands' database provided by a company was utilized. This database was constructed from visual analysis of Sentinel-2 images from the year 2020. The accuracy of the map was validated using the Kappa coefficient. Reference data for harvesting was also obtained through visual interpretation by analyzing a five-year history of Sentinel-2 images. Each year, the best images from each quarter were selected, identifying changes in spectral response from forest to exposed soil, indicating harvesting. In constructing the harvest detection algorithm, land cover classes provided by the European Space Agency (ESA) between 2019 and 2020 were used, employing the Scene Classification (SCL). This product offers land cover information for each Sentinel-2 image collected every five days. Subsequently, classes of interest (cloud, soil, and vegetation) were filtered. To acquire an image with fewer cloud cover instances, three temporal categories (monthly, bimonthly, and quarterly) were analyzed, generated by aggregating weekly images. SCL classes were intersected with Eucalyptus stands, determining the temporal category with the least cloud cover in the stand database. Once the best temporal category was defined, harvest detection relied on accumulating pixels classified as soil in each new image composition, evaluating the percentage of soil in the stand. Experimentations were conducted to define the best soil percentage threshold to consider a stand as harvested. To calculate algorithm accuracy, performance evaluations were done with two distinct strategies. Strategy 1 directly compared the algorithm-identified harvest month with the reference date for each Eucalyptus stand. Strategy 2 assessed algorithm accuracy by varying one month before and after the reference date. Subsequently, the impact of slope and stand size on algorithm accuracy was analyzed, calculating errors and successes for each slope class and stand size. The Eucalyptus map obtained a Kappa of 0.851 and an overall accuracy of 94%. The quarterly temporal category proved most effective in minimizing cloud effects, as no stand exhibited over 20% cloud coverage. Strategy 2 was the most efficient, achieving an algorithm accuracy of 84.5% with a 25% soil threshold. It was observed that higher slopes corresponded to lower accuracy, while stand size showed a direct relationship: larger size led to higher accuracy. The developed algorithm represents an advancement in applying new monitoring and oversight methods for Eucalyptus plantations, and it can be adopted by the public sector.

Keywords: remote sensing; land use; plantations forest.

LISTA DE FIGURAS

Figura 1 – Fotografia aérea de um plantio de <i>Eucalyptus</i> no município de Bocaiúva-MG.	16
Figura 2 – Harvester (A) e Feller-Buncher (B).....	18
Figura 3 – Sensoriamento Remoto Orbital.	21
Figura 4 – Esquema de avaliação de consistência temporal de séries temporais. a) Criação de análises no tempo e espaço; (b) extração de uma série temporal de índice de vegetação, para analisar um mesmo pixel.	26
Figura 5 – Mapa hipsométrico do Estado do Espírito Santo. Utilizando dados SRTM, com escala de mapeamento de 1;250.000, Sistema de coordenadas Geográficas SIRGAS 2000.....	32
Figura 6 – Mapa de floresta plantada e divisão de quadrantes do Estado do Espírito Santo.....	33
Figura 7 – Florestas de <i>Eucalyptus</i> (coloração avermelhada) e nativas (coloração marrom) de uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red).....	34
Figura 8 – Detalhamento dos limites dos talhões mapeados sobre uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red), município de São Mateus-ES.....	36
Figura 9 – A) Localização dos pontos de controle do mapeamento coletado em campo. B) exemplo das classes dos pontos coletadas em campo sobre uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red).	37
Figura 10 – Ilustração dos padrões de tonalidade, textura e contexto observados nas imagens Sentinel-2 para a definição do gênero plantado. Os gráficos na porção inferior mostram séries temporais de um índice de vegetação (NDVI), utilizadas para descrever a velocidade de crescimento das florestas e a duração da rotação.	38
Figura 11 – Ilustração mostrando uma imagem do <i>Google Street View</i> de um plantio de <i>Eucalyptus</i>	39
Figura 12 – Ilustração da resposta espectral de um plantio de eucalipto ao longo de uma série temporal de cinco anos de imagens trimestrais Sentinel-2/Landsat (composição falsa-cor R8A-G11-B4).....	40
Figura 13 – Fluxograma ilustrando o processamento no algoritmo de detecção de nuvem.	43

Figura 14 – Esquema sintetizando a construção das imagens de máximo mensais, bimestrais e trimestrais.	45
Figura 15 – Esquema resumindo o acúmulo do solo ao longo dos trimestres de um talhão de Eucalipto.	47
Figura 16 – Distribuição de frequência de talhões (%) por classe de nuvem dentro de cada talhão em diferentes períodos temporais.....	51
Figura 17 – Acurácia da detecção em função da porcentagem de solo do talhão comparado com a referência em campo.	52
Figura 18 – Gráfico da porcentagem de floresta (PV) e de solo (PS), de um polígono colhido, ao longo dos trimestres, até acontecer uma colheita.	54
Figura 19 – Mapa do desempenho do algoritmo por mesorregião	54
Figura 20 – Mapa do desempenho do algoritmo por mesorregião	57

LISTA DE TABELAS

Tabela 1 – Classes do coeficiente Kappa	36
Tabela 2 – Lista de classes de classificação de cena (SCL) do Sen2Cor e cores correspondentes.....	41
Tabela 3 – Matriz de erros obtidas com a avaliação de 1605 pontos de controle obtidos em campo utilizando o GPS	49
Tabela 4 – Relação entre declividade do terreno e acurácia da detecção de colheita de povoamentos de <i>Eucalyptus</i>	55
Tabela 5 – Acurácia da detecção de colheita de povoamentos de <i>Eucalyptus</i> em função do tamanho dos talhões (ha).	55

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	15
2.1	OBJETIVO GERAL	15
2.2	OBJETIVOS ESPECIFICOS.....	15
3	REFERENCIAL TEÓRICO	16
3.1	O GÊNERO <i>EUCALYPTUS</i>	16
3.1.1	Colheita de <i>Eucalyptus</i>	17
3.1.2	Fiscalização em áreas de florestas plantadas no Espírito Santo	19
3.2	SENSORIAMENTO REMOTO PARA CLASSIFICAÇÃO DE IMAGENS	20
3.2.1	Sentinel-2	22
3.2.2	Deteção de mudança de cobertura da terra	25
3.2.3	Sistemas de deteção de mudança de uso e cobertura do solo	29
4	METODOLOGIA	31
4.1	ÁREA DE ESTUDO	31
4.2	BASE DE REFERÊNCIA DE FLORESTA PLANTADA NO ES.....	33
4.2.1	Mapeamento de limites dos talhões de <i>Eucalyptus</i>	34
4.2.2	Definição do gênero plantado	37
4.2.3	Definição do dado de referência de colheita de povoamentos de <i>Eucalyptus</i>	39
4.3	PROCESSAMENTO DE IMAGENS.....	40
4.3.1	Aplicação do algoritmo Sen2cor	41
4.4	AVALIAÇÃO DO DADO DE NUVEM	43
4.5	DETECÇÃO AUTOMÁTICA DE ÁREAS COLHIDAS	46
5	RESULTADO E DISCUSSÕES	49
5.1	VALIDAÇÃO DO MAPEAMENTO DAS ÁREAS DE FLORESTA PLANTADAS DE <i>EUCALYPTUS</i> NO ESPÍRITO SANTO.....	49
5.2	ANÁLISE DA PRESENÇA DE NUVENS NAS IMAGENS SENTINEL-2 DO ESPÍRITO SANTO	49
5.3	ALGORITMO DE COLHEITA FLORESTAL DE POVOAMENTOS DE <i>EUCALYPTUS</i>	52

5.4	ANÁLISE DO EFEITO DO RELEVO E TAMANHO DE POLÍGONO NA ACURÁCIA DO ALGORITMO DE DETECÇÃO DE COLHEITA	54
6	CONCLUSÃO	57
	REFERÊNCIAS	59

1 INTRODUÇÃO

Os plantios florestais estão presentes em mais de 219 países, ultrapassando a área de 131 milhões de hectares, representando 3,12% de toda a cobertura florestal do planeta (FAO, 2020). Desse total, os gêneros mais comuns são *Pinus* e *Eucalyptus* (30%), totalizando 39 milhões de hectares (CARNUS *et al.*, 2006). No Brasil, a indústria de base florestal apresentou 9,94 milhões de hectares de floresta plantada em 2021, representando 7,6% do total de plantios florestais no mundo, destacando o gênero *Eucalyptus*, com aproximadamente 7,6 milhões de hectares (76%) e o gênero *Pinus*, com aproximadamente 1,92 milhões de hectares (19%) (IBA,2023). Segundo a IBA (2023) o setor florestal tem um impacto para economia brasileira, contribuindo com um acréscimo ao produto interno bruto (PIB) de 1,3% em 2022, gerando um total de R\$ 260 bilhões.

Segundo o Centro de Desenvolvimento do Agronegócio - CEDAGRO (2022), no estado do Espírito Santo, a área de floresta plantada corresponde a, aproximadamente, 280 mil hectares, destacando-se os plantios de *Eucalyptus* com mais de 264 mil hectares (94,4%), correspondendo 6% da área total do estado. O setor florestal tem grande importância no estado, impactando em 7,9% do PIB e 50% das exportações do agronegócio capixaba (CEDAGRO, 2022).

A gestão eficiente das áreas com cobertura florestal depende da capacidade de monitoramento e fiscalização dos órgãos ambientais. Por exemplo, no Espírito Santo, o Instituto de Defesa Agropecuária e Florestal (IDAF) é o órgão que fiscaliza as áreas de florestas plantadas, objetivando o controle das atividades de exploração. Entretanto, o poder público estadual não possui instrumentos que permitam um monitoramento sistemático das áreas de florestas plantadas, assim como a quantificação do estoque de madeira produzido e consumido (IDAF, 2021).

Uma das formas de diminuir este problema é o uso de técnicas de sensoriamento remoto orbital, que possibilitam o monitoramento de áreas florestais de forma sistemática, viabilizando a vigilância por órgãos ambientais em larga escala (CHUVEICO, 2019). No entanto, o sensoriamento remoto orbital enfrenta desafios, como a interferência das nuvens, identificação de objetos devido à resolução espacial das imagens e a influência do relevo, em decorrência do ângulo de incidência solar, que afetam a precisão das análises (HORNING, 2010).

Já existem sistemas de monitoramento de floresta natural que emitem alertas de desmatamento, tais como os sistemas Programa de Cálculo do Desflorestamento da Amazônia (PRODES) e Sistema de Detecção do Desmatamento em Tempo Real (DETER), operados pelo Instituto Nacional de Pesquisas Espaciais (INPE) (ALMEIDA, *et al.*, 2021). O MapBiomias é outro projeto de mapeamento com a finalidade de identificar a cobertura do solo. Nesse sistema são disponibilizadas coleções de mapas anuais da dinâmica de mudança de uso e cobertura do solo, de 1985 até 2023, e tem como objetivo realizar atualizações anuais (SOUZA e AZEVEDO, 2017).

Vale ressaltar que os mapas disponibilizados pelo MapBiomias são confeccionados em uma escala anual. Assim, o entendimento da dinâmica de plantio e de colheita florestal de um gênero que apresenta um rápido crescimento, como o eucalipto, se torna um desafio. Os povoamentos de *Eucalyptus* já responde nas imagens do satélite Sentinel-2, com composição de cor verdadeira, após 2 meses do plantio, fazendo com que a atualização anual não seja tão sensível a dinâmica do eucalipto (EMBRAPA, 2014). Além disso, os sistemas de monitoramento descritos anteriormente utilizam dados de satélites ópticos que, nas épocas chuvosas, podem passar meses sem coletar informações de certas áreas em função da cobertura de nuvens (SOUZA e AZEVEDO, 2017; ALMEIDA *et al.*, 2021). Além disso, a maior parte dos sistemas desenvolvidos até então focam no monitoramento de corte raso em florestas naturais.

Diante do exposto, torna-se necessário o desenvolvimento de ferramentas que visam minimizar os efeitos da cobertura de nuvens em sistemas de monitoramento florestal, e que esses sistemas tenham resoluções temporais para acompanhar a dinâmica de florestas plantadas de rápido crescimento.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver uma metodologia para detecção da colheita de plantios de *Eucalyptus*, no estado do Espírito Santo, com dados ópticos do satélite Sentinel-2.

2.2 OBJETIVOS ESPECIFICOS

- Analisar o comportamento de nuvem nas imagens do estado do Espírito Santo;
- Analisar a acurácia da detecção da colheita dos talhões de *Eucalyptus*;

- Analisar o efeito do relevo na acurácia de detecção de colheita de povoamentos de *Eucalyptus*;
- Analisar o efeito do tamanho do talhão na acurácia de detecção de colheita de povoamentos de *Eucalyptus*.

3 REFERENCIAL TEÓRICO

3.1 O GÊNERO *EUCALYPTUS*

O eucalipto (Figura 1) é uma árvore do gênero *Eucalyptus*, pertencente à família Myrtaceae. Existem mais de 730 espécies diferentes de eucalipto, a maioria das quais é nativa da Austrália, embora tenha ocorrência em diversas partes do mundo devido à sua adaptação a diferentes climas e solos (VITAL, 2007). Entretanto, apenas 20 delas são utilizadas comercialmente, em todo mundo (ANDRADE *et al.*, 2014; SCHUMACHER e VIERA, 2016).

Figura 1 – Fotografia aérea de um plantio de *Eucalyptus* no município de Bocaiúva-MG.



Fonte: Autor (2021).

No Brasil, a história da cultura de eucalipto teve início nos primeiros anos do século XX, embora sua introdução inicial foi no século anterior. Nessa época, o eucalipto desempenhou um papel com menor importância, sendo empregado como quebra-ventos, ornamento paisagístico e matéria-prima para a extração de óleo vegetal. No entanto, foi nas décadas subsequentes que a cultura do eucalipto se consolidou de forma notável (VITAL, 2007; SCHUMACHER e VIERA, 2016).

No final da década de 1930, o eucalipto já era plantado em escala comercial, marcando um ponto de virada em sua história no Brasil. A madeira de eucalipto passou a ser utilizada na produção de dormentes, que desempenharam um papel crucial na construção de residências e estradas de ferro (FOELKEL, 2007). Além disso, o eucalipto tornou-se uma valiosa fonte de combustível, sendo empregado tanto na siderurgia quanto em fornos domésticos. Esse desenvolvimento representou um marco importante na indústria florestal e contribuiu substancialmente para a economia brasileira (SCHUMACHER e VIERA, 2016).

As espécies de eucalipto têm sido preferidas devido a uma série de vantagens (ANDRADE *et al.*, 2014). Seu crescimento rápido, habilidade de adaptação a diversas regiões ecológicas e seu potencial econômico, devido à diversidade de usos de sua madeira, contribuem para ser o gênero mais plantado. As rotações de, geralmente, sete anos aproximadamente, reduzem custos e proporcionam taxas de retorno de investimento mais elevadas, tornando o cultivo do eucalipto atraente, garantindo uma competitividade para seus produtos, tanto no mercado interno quanto no externo (SCHUMACHER e VIERA, 2016).

3.1.1 Colheita de *Eucalyptus*

A colheita florestal é definida como um conjunto de procedimentos realizados no ambiente de um maciço florestal, com o objetivo de preparar e extrair a madeira até o ponto de destino para transporte, empregando métodos e padrões estabelecidos com a finalidade de transformá-la em um determinado produto (MACHADO, 2002). Esta etapa de colheita, considerada de suma relevância sob uma perspectiva técnica e econômica, engloba diversas fases, tais como o corte das árvores (incluindo atividades de derrubada, desgalhamento e processamento ou traçamento), bem como o descascamento, quando efetuado *in loco*. Além disso, abrange as operações de

extração e carregamento compreendendo todas as tarefas desde a preparação das árvores para a colheita até o seu transporte ao destino (SANTOS, 2000). A execução da operação de colheita pode, em certos contextos, também abranger aspectos como o planejamento da operação, a medição da madeira, a recepção desta no pátio da indústria e a sua posterior comercialização (FREITAS, 2005).

No setor florestal, a colheita e transporte de madeira são etapas cruciais, tanto do ponto de vista econômico quanto da gestão de riscos, devido à sua elevada participação no custo final do produto. Entre os custos de produção de celulose, cerca de 40% a 50% são referentes ao produto florestal, dos quais aproximadamente a metade se refere aos custos de colheita e transporte (ANDRADE, 1998).

A colheita florestal pode ser conduzida mediante duas abordagens principais (MACHADO, 2008): a mecanizada, que envolve o uso de equipamentos especializados, tais como "Harvesters" (Figura 2a) e "Feller-Bunchers" (Figura 2b), e a semimecanizada, que faz uso de ferramentas manuais como motosserras. Vale enfatizar o papel fundamental desempenhado pela mecanização no contexto das operações de colheita florestal.

Figura 2 – Harvester (A) e Feller-Buncher (B).



Fonte: Autor (2023).

No Brasil, os sistemas manuais e semimecanizados de colheita foram amplamente empregados, principalmente devido à falta de alternativas, levando a altos custos e riscos significativos. No entanto, com o aumento da demanda por produtos florestais, a necessidade de maior eficiência operacional, a escassez de mão

de obra, o aumento dos custos sociais e a abertura do mercado às importações de máquinas de alta tecnologia, houve uma intensificação da mecanização do setor florestal (MENDONÇA FILHO, 1987).

A liberação das importações no final da década de 90 resultou em um aumento na adoção de métodos mecanizados para a colheita de madeira. Esse desenvolvimento culminou em ganhos substanciais, no que diz respeito à eficiência da utilização de mão de obra, além de uma redução na frequência e na gravidade dos acidentes de trabalho associados a essa atividade. Conseqüentemente, observou-se uma tendência contínua de elevação do grau de mecanização na colheita florestal (BRAMUCCI, 2001).

3.1.2 Fiscalização em áreas de florestas plantadas no Espírito Santo

No Espírito Santo, o Instituto de Defesa Agropecuária e Florestal (IDAF) faz o monitoramento da cobertura florestal, conforme o disposto no inciso XX do art. 39 da Lei Estadual nº 5.361/1996, que define a Política Florestal do estado (ESPÍRITO SANTO, 1996). Além do monitoramento de florestas nativas, com fins de preservação e fiscalização de crimes ambientais, cabe também ao IDAF o monitoramento das áreas de florestas plantadas, objetivando a fiscalização e controle das atividades de exploração.


A autorização da exploração de florestas plantadas com espécies exóticas é concedida pelo IDAF por meio da emissão de um documento denominado Informação de Corte (IC). De acordo com o art. 2º da Instrução Normativa 01 de 09 de janeiro de 2020 (ESPÍRITO SANTO, 2020), para a obtenção da Informação de Corte o interessado deve informar o empreendimento em que será realizada exploração, a área ou o número de árvores a serem exploradas, a espécie, a idade do plantio, o volume do rendimento e o tipo de material obtido, bem como sua destinação. Após o pagamento de uma taxa, calculada em função do rendimento lenhoso estimado para a exploração (m³), a IC é emitida e o requerente se torna apto a iniciar a colheita florestal. É importante ressaltar que a informação sobre o rendimento volumétrico da exploração é definida pelo interessado de forma declaratória, não sendo exigido nenhum documento técnico que comprove o volume informado, como é o caso de relatório de um inventário florestal.

As técnicas de sensoriamento remoto, que possibilitam a obtenção de informações de alvos terrestres, vêm sendo empregadas com sucesso no monitoramento para resolução de problemas ambientais, agrícolas e até mesmo urbano. O uso de imagens de satélite pode possibilitar a detecção automática da colheita florestal em todo o estado, em tempo quase real (CHUVEICO, 2019). Com esse tipo de informação, o governo poderia obter autonomia total na fiscalização da colheita de florestas plantadas, não só validando os dados de volume fornecidos por produtores e empresas florestais na IC, mas também monitorando explorações irregulares. A introdução dessas tecnologias de sensoriamento remoto na rotina operacional de qualquer órgão do Estado, com o objetivo de monitorar áreas de interesse, pode ser fundamental para superar alguns desafios, tais como a demanda elevada de tempo e pessoal para a execução de fiscalizações in loco, a necessidade de planejamento logístico prévio e as dificuldades de acesso a áreas de interesse, entre outros.

3.2 SENSORIAMENTO REMOTO PARA CLASSIFICAÇÃO DE IMAGENS

O sensoriamento remoto é um conjunto de técnicas que possibilitam a obtenção de informações sobre objetos presentes na superfície terrestre, sem a necessidade de contato direto com eles (CHUVEICO, 2019). Essas informações podem ser adquiridas por meio de sensores instalados em plataformas aéreas, orbitais ou terrestres, sendo esta última tanto móvel quanto fixa, que captam e registram a energia refletida ou emitida pelos objetos em estudo (Figura 3). Essas informações são processadas e transformadas em imagens ou dados (MORAES, 2002).

Figura 3 – Sensoriamento Remoto Orbital.



Fonte: Formaggio e Sanches (2017).

Os sensores remotos podem ser divididos em duas categorias de acordo com a fonte de radiação eletromagnética (REM) utilizada (MORAES, 2002), passivos e ativos. Os sensores passivos são aqueles que operam registrando a energia emitida pelo sol que é refletida pela superfície terrestre e, por isso, dependem de fontes externas de REM. Os exemplos mais comuns de sensores passivos são os satélites ópticos, como o Sentinel-2 e os da série Landsat (5, 7, 8 e 9). Esses satélites são capazes de capturar imagens de média resolução espacial e temporal da superfície terrestre. Por outro lado, os sensores ativos possuem fontes próprias de REM, o que significa que não dependem de fontes externas de radiação para funcionar. Eles emitem pulsos de energia eletromagnética que são refletidos pelos objetos da superfície terrestre, permitindo a obtenção de informações sobre esses objetos. Além disso, conseguem muitas vezes operar durante a noite e atravessar as nuvens, o que é um diferencial em relação aos sensores passivos. Um exemplo de sensor ativo é o Sentinel-1, fornece imagens de radar de alta resolução da superfície terrestre (TORRES, 2002).

As informações obtidas por meio de sensoriamento remoto são processadas em sistemas de informação geográfica (SIG), e podem ser analisadas de diversas formas. Uma delas é por meio da interpretação visual, enquanto outra maneira é por

meio de algoritmos de classificação que se baseiam nas respostas espectrais de pixels ou regiões homogêneas (CROSTA, 1992). O processamento digital de imagens é um dos métodos utilizados para relacionar essas informações e facilitar a análise dos dados obtidos.

Uma das tarefas importantes em sensoriamento remoto é a classificação de imagens ópticas, que consiste em agrupar e classificar partes das imagens correspondentes em classes morfológicas, como terra, água, nuvem, floresta e agricultura, entre outras (MOHAJERANI, KRAMMER e SAEEDI, 2018). A classificação de imagens tem sido objeto de muitas pesquisas, sendo considerado um campo desafiador e que concentra grande volume de estudos (RAIYANI *et al.*, 2021).

A correta classificação de alvos nas imagens de satélite pode contribuir para o planejamento e monitoramento em diversas áreas, como a ambiental, social, avaliação de risco e impacto (DAO e LIOU, 2015). Entretanto, essa classificação pode sofrer com alguns fatores (VENTURIERI, 1998). Um deles, são os pixels de borda, que podem impactar no desempenho de algoritmos. Outro ponto a ser considerado é a mistura espectral. Nas imagens, polígonos pequenos podem cobrir áreas que contêm várias classes de cobertura terrestre. Isso resulta na mistura espectral, onde os pixels dentro do polígono podem apresentar assinaturas espectrais de diversas classes diferentes (BITTENCOURT e HAERTEL, 2009). Essa mistura torna a classificação mais desafiadora, pois é necessário separar as diferentes classes presentes em uma pequena área (BLASCHKE, 2005).

O relevo desempenha um papel fundamental na acurácia no mapeamento, pois a incidência dos raios solares é um fator crítico a ser considerado na obtenção das imagens. A orientação das encostas em relação ao sol pode causar sombreamento em áreas inclinadas, criando diferenças nas assinaturas espectrais e afetando a qualidade das imagens de satélite. Isso pode levar a erros na classificação e interpretação das imagens (MORAES NOVO, 2010).

3.2.1 Sentinel-2

O Sentinel-2 é uma missão espacial que faz parte do programa European Copernicus Earth, promovido pela Agência Espacial Europeia (ESA), que compreende dois satélites ópticos, o Sentinel-2A e o Sentinel-2B. Ambos possuem orbitas polares

(ou quase polares), isto é, o movimento de revolução dos satélites passa próximo dos polos (Antártico e Ártico), coletando imagens tanto do continente como do litoral do globo. A missão iniciou-se em 2015, com a colocação do satélite 2A em órbita, porém a constelação Sentinel-2 só ficou completa em 2017, com a chegada do 2B. Cada um dos satélites carrega um sensor multiespectral (MSI), podendo ser usado na agricultura, silvicultura, meteorologia e outras aplicações relacionadas (ESA, 2015).

Os dados da missão do Sentinel-2 são disponibilizados de forma gratuita, com resolução: Espectral, refere-se à capacidade de um sensor ou instrumento de detectar e registrar diferentes comprimentos de onda do espectro eletromagnético, variando de 443nm a 2190nm.; espacial, se refere ao tamanho do pixel presente na imagem, ficando entre 10 metros a 60 metros, dependendo da banda, quatro delas com 10m, seis delas com 20 metros e três delas com 60 metros; temporal, é quanto tempo o satélite revisita um mesmo ponto na superfície da terra, a do Sentinel-2 leva 5 dias considerando os dois satélites (ESA, 2015).

Os níveis de processamento das imagens do Sentinel-2 representam uma série de estágios sequenciais nos quais os dados brutos adquiridos pelo satélite Sentinel-2 são processados em diversos níveis que podem ser utilizadas em análises científicas e aplicações práticas. Esses níveis, que vão desde o Nível 0 até o Nível 2A e além, envolvem correções, calibrações e transformações que visam melhorar a qualidade e a utilidade das imagens, tornando-as adequadas para uma ampla gama de aplicações, como o monitoramento ambiental, agrícola e de uso do solo. Cada nível representa um estágio específico de processamento, contribuindo para a precisão e prontidão dos dados à medida que avançam (ESA, 2015).

O nível zero (Nível-0) dos dados do Sentinel-2 é o estágio inicial de processamento dos dados adquiridos pelo satélite antes de qualquer correção ou calibração significativa ser aplicada. Neste nível, os dados são adquiridos diretamente pelo satélite e representam informações brutas que são transmitidas à Terra. Representa a etapa inicial de processamento dos dados brutos do satélite. Esses dados são a base para todas as etapas subsequentes de correção, calibração e processamento que ocorrem nos níveis posteriores, permitindo que sejam transformados em informações cientificamente úteis para uma variedade de aplicações como monitoramento ambiental, agrícola e florestal (ESA, 2015).

Os níveis 1A, 1B e 1C representam etapas de processamento dos dados do Sentinel-2 após a fase inicial de aquisição (Nível 0). Cada um desses níveis envolve

correções e calibrações adicionais para tornar os dados mais úteis e precisos para análises científicas. No Nível 1A, os dados brutos do satélite são processados para realizar correções radiométricas e geométricas iniciais. Isso inclui a correção da radiometria para garantir que as leituras dos sensores estejam em unidades de radiância. Além disso, a correção geométrica é aplicada para remover distorções causadas pela órbita do satélite e pela rotação da Terra (ESA, 2015). No Nível 1B, os dados são calibrados e georreferenciados com maior precisão. Isso significa que os valores de radiância são ajustados para contabilizar variações na órbita do satélite, na inclinação do sensor e na distância entre o sensor e a superfície da Terra. Os dados no Nível 1B também são georreferenciados, o que significa que as informações são registradas em um sistema de coordenadas geográficas, permitindo que as imagens sejam sobrepostas com precisão em um mapa (ESA, 2015). No Nível 1C, os dados são processados para realizar correções atmosféricas e criar produtos mais avançados. Isso envolve a correção de efeitos atmosféricos nas imagens para remover influências da atmosfera e criar produtos corrigidos para refletâncias na superfície da terra. Além disso, produtos derivados, como imagens de reflectância na superfície e índices de vegetação, são gerados no Nível 1C. Esses produtos são mais adequados para análises científicas como monitoramento ambiental, agrícola e de uso do solo (ESA, 2015).

O processamento de Nível 2A (L2A) dos dados do Sentinel-2 representa uma etapa avançada após o processamento de Nível 1C (L1C), utilizando o algoritmo *sen2cor*, e envolve correções adicionais de natureza atmosférica e geométrica. É importante notar que tais correções exercem influência sobre a distribuição espacial e espectral da radiação eletromagnética emitida pelo Sol antes de sua chegada à superfície terrestre. Em consequência, a energia refletida que é registrada por um sensor de satélite sofre impactos e atenuações, tornando imperativa a realização de uma correção atmosférica (ESA, 2015).

A correção atmosférica representa o procedimento em que os efeitos da atmosfera sobre os valores de reflectância na parte superior da atmosfera (TOA) das imagens originais de satélite são mitigados. A reflectância TOA é uma medida adimensional que estabelece a relação entre a radiação refletida e a radiação solar incidente em uma superfície específica. Em contraste, a reflectância da parte inferior da atmosfera (BOA) se define como a fração da radiação solar incidente que é refletida pela superfície da Terra. Essas intervenções tornam os dados mais propícios para

análises científicas e atividades de monitoramento, uma vez que preservam a consistência entre as imagens (ESA, 2015). Essas imagens corrigidas oferecem uma precisão radiométrica superior, eliminando distorções causadas por fenômenos atmosféricos, como dispersão da luz, reflexões e absorções. Isso não apenas melhora a fidelidade na representação das propriedades dos alvos na superfície terrestre, mas também permite a comparabilidade entre diferentes datas de aquisição. Essa capacidade de comparar imagens de períodos distintos é crucial para estudos temporais e análises de mudanças ao longo do tempo (SIMONETTI, 2021; ESA, 2015). Além disso, ao minimizar interferências atmosféricas, como nuvens, névoa ou gases, as imagens corrigidas proporcionam uma qualidade de dados aprimorada. Isso facilita a identificação de características e padrões relevantes para uma variedade de disciplinas científicas, incluindo ecologia, agricultura, geologia, monitoramento ambiental e estudos climáticos (SIMONETTI, 2021; ADEU, 2020).

Pelo Sentinel-2 apresentar as vantagens descritas acima, eles são satélites amplamente utilizados em pesquisas no campo do sensoriamento remoto. Em mapeamento de uso e cobertura da terra, sendo ideal para estudos que levam em conta uma escala macro, sem perder a acurácia de elementos mais finos (SIMONETTI, 2021). Vale ressaltar ainda a grande base temporal de imagens disponíveis desde 2015, que permite compreender a evolução da mudança de uso e cobertura.

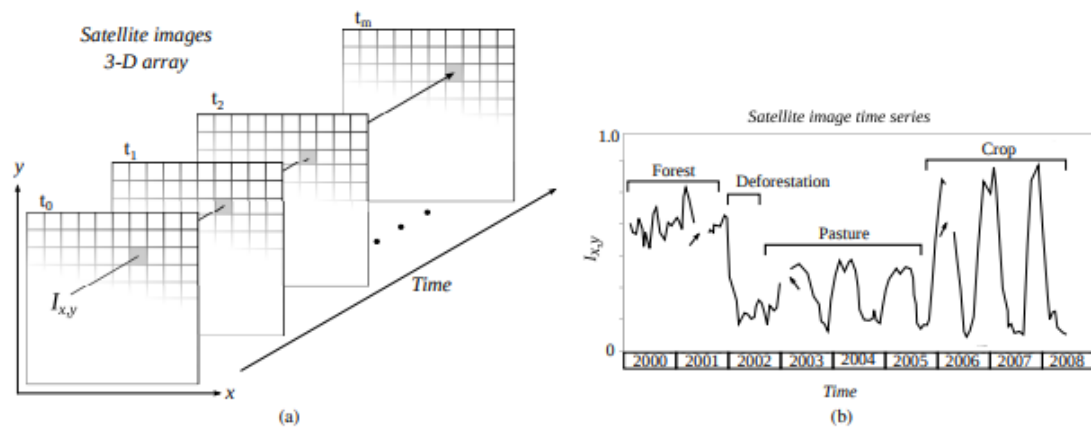
3.2.2 Detecção de mudança de cobertura da terra

O uso de técnicas de sensoriamento remoto para identificação do uso e cobertura da terra tem sido alvo de diversas pesquisas nas últimas décadas. A utilização das imagens de satélite tem um papel crucial no diagnóstico e monitoramento dos processos de uso e cobertura da terra. As imagens fornecem informações valiosas sobre os fenômenos que ocorrem na superfície da Terra, desempenhando um papel essencial na compreensão e modelagem das dinâmicas das mudanças, percebidas principalmente por meio da consistência temporal que as imagens possuem junto a algoritmos que permitem esse tipo de avaliação (FERREIRA *et al.*, 2010).

A partir da revisitação periódica de satélites a um mesmo ponto geográfico, torna-se possível manter a consistência das imagens obtidas, assegurando a

comparabilidade dos imageamentos realizados em momentos temporais diferentes e periódicos (Figura 4a). Essas observações podem ser organizadas de maneira em que cada observação pode ser localizada tridimensionalmente em espaço, tempo e distância. A cada coordenada de pixel (x, y) em momentos temporais consecutivos, pode-se extrair informações espectrais podendo assim construir gráficos que se expressam no tempo e no espaço a resposta espectral (Figura 4b). A partir dessas séries temporais, emerge a capacidade de extrair informações pertinentes ao uso da terra e à cobertura vegetal. (ADEU, 2020).

Figura 4 – Esquema de avaliação de consistência temporal de séries temporais. a) Criação de análises no tempo e espaço; (b) extração de uma série temporal de índice de vegetação, para analisar um mesmo pixel.



Fonte: Maus *et al.* (2016)

Existem diversas técnicas que têm sido desenvolvidas para fins de detecção de mudanças por sensoriamento remoto, incluindo o uso de algoritmos de registro espacial entre as cenas, segmentação de imagens e análise de vetores diferença (CVA). A detecção de mudanças por meio da técnica de imagem de diferença univariada é um método simples e eficaz. Esta técnica opera por meio da subtração dos valores de pixel de imagens registradas. Geralmente, é realizada por banda espectral. Se poucas mudanças ocorrem, os valores de pixel da imagem de diferença revelam variações sutis na distribuição (SINGH, 1989).

O primeiro passo essencial é o registro preciso das imagens, garantindo seu alinhamento para corresponderem à mesma área geográfica. Em seguida, ocorre a subtração dos valores de pixel entre as imagens correspondentes. Isso significa que os valores numéricos de uma imagem são deduzidos dos valores correspondentes na

outra imagem (SINGH, 1989). Como resultado desse procedimento é obtida a imagem de diferença que destaca as mudanças ocorridas entre os dois momentos de aquisição. Valores positivos indicam um aumento nos valores de pixel entre os períodos, enquanto valores negativos indicam uma redução.

No registro espacial entre as cenas, Xiaolong e Khorram (1998) e Bruzzone e Cossu (2003) investigaram maneiras para reduzir os efeitos do erro no registro das imagens utilizadas. Os registros automáticos produzem resultados com considerável precisão e têm sido empregados com frequência em etapas anteriores à disponibilização dos dados.

Com a disponibilidade de imagens de média e alta resolução espacial, algoritmos de segmentação de imagens têm sido utilizados de maneira crescente (BLASCHKE, 2005). Bovolo (2009) e Dalla Mura *et al.*, (2008) mostraram que mesmo que não haja perfeita sobreposição entre polígonos, a utilização de estratégias específicas pode produzir resultados muito satisfatórios na detecção de mudanças baseada em objetos.

Uma abordagem que tem mostrado particular eficiência na detecção de desflorestamento é a análise de vetores diferença (CVA). Essa técnica foi proposta por Malila (1980) para aplicações em monitoramento florestal. A técnica consiste no estabelecimento de um limiar aplicado à magnitude dos vetores espectrais de mudança (SCV). Um aprimoramento dessa técnica foi sugerido em Bovolo e Bruzzone (2007) na aplicação de CVA no domínio hiperesférico. Sua principal vantagem é a utilização das direções multidimensionais apresentadas por cada SCV, além de suas magnitudes.

Uma abordagem adicional envolve a utilização de índices de vegetação (IV) em análises destinadas à detecção de mudanças na cobertura e no uso da terra, incorporando análises multitemporais desses índices. Entre os IV amplamente empregados para essa finalidade, destacam-se o Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação Ajustado ao Solo (SAVI), Índice de Vegetação Melhorado (EVI) e Índice de Diferença Normalizada de Água (NDWI).

O NDVI (Equação 1) é calculado a partir da reflectância no infravermelho próximo (NIR) e no vermelho (RED) e gera valores no intervalo entre -1 e 1.

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

O SAVI (Equação 2) é uma variação do NDVI que considera a presença de solo exposto, por meio de um fator de ajuste.

$$SAVI = \frac{NIR-RED}{NIR+RED+L} * (1 + L) \quad (2)$$

O EVI (Equação 3) utiliza as bandas azul, vermelha e infravermelho próximo (NIR) e possui uma correção atmosférica, além de minimizar a interferência de solo exposto.

$$EVI = 2,5 \frac{NIR-RED}{[(NIR)+(C1*RED)-(C2*BLUE)+L]} \quad (3)$$

O NDWI (Equação 4) utiliza as bandas do NIR e do infravermelho de onda curta (SWIR) identificando presença de água.

$$NDWI = \frac{GREEN-NIR}{GREEN+NIR} \quad (4)$$

Para detectar a mudança é realizada a comparação de valores de índice entre duas ou mais imagens de satélite adquiridas em diferentes datas em classes já conhecidas. A diferença entre os valores do índice em diferentes datas é calculada e um limiar é estabelecido para determinar se houve mudança significativa na vegetação (JONES e VAUGHAN, 2010) (MATSUSHITA *et al.*, 2007).

No estudo de Reiche *et al.*, (2015), uma abordagem para a detecção de mudanças em imagens de sensoriamento remoto fundamentada na análise Bayesiana é apresentada. Essa análise consiste em um método estatístico que utiliza a teoria das probabilidades para atualizar hipóteses com base na observação de novos dados. Na metodologia proposta, modelos estatísticos são definidos para as imagens multitemporais a serem comparadas, incluindo distribuições de probabilidade para os pixels antes e depois da mudança. Essas distribuições, que podem ser gaussianas, têm seus parâmetros (média e desvio padrão) estimados a partir dos valores dos pixels nas imagens. A probabilidade de mudança em cada pixel é então estimada usando a teoria da probabilidade condicional, com um limiar de probabilidade estabelecido para definir a área de interesse. Pixels com probabilidade acima desse

limiar são considerados como tendo sofrido mudança. Em Chaves *et al.*, (2020) pode ser encontrada uma refinada e atualizada revisão de literatura sobre o tema, focado em imagens de resolução especial medianas, 10 metros para o Sentinel-2 e 30 metros para o Landsat 8.

3.2.3 Sistemas de detecção de mudança de uso e cobertura do solo

Uma ferramenta útil para avaliar a mudança do uso e cobertura do solo são os sistemas de detecção. Existem diversos sistemas com o objetivo de monitoramento para florestas nativas que emitem alertas de desmatamento. Um exemplo é o Programa de Cálculo do Desflorestamento da Amazônia (PRODES), operado pelo Instituto Nacional de Pesquisas Espaciais (INPE) (ALMEIDA, 2021). Outro sistema é o *Global Forest Watch* (GFW), lançado em 2014 pelo Instituto de Recursos Mundiais, que se concentra em questões ambientais globais e utiliza tecnologias avançadas para rastrear mudanças nas florestas do mundo em tempo real. Além desses sistemas, é importante destacar o *MapBiomas*, que se diferencia dos já citados por ser focado em monitorar a cobertura e o uso do solo no Brasil ao longo do tempo, não apenas em florestas.

O PRODES é um programa que monitora e documenta as mudanças na cobertura florestal da Amazônia brasileira, especialmente o desmatamento, e utiliza imagens de satélite e técnicas de análise de dados. Este programa tem como objetivo medir a taxa de desmatamento da Amazônia e produzir relatórios anuais. Por meio de fotointerpretação por especialistas, o programa realiza anualmente o mapeamento dos incrementos de desmatamento por corte raso ou por degradação progressiva da vegetação primária, que levam à remoção da cobertura florestal primária nas formações florestais ou à supressão da vegetação primária em formações não florestais.

O GFW é uma plataforma que fornece informações em tempo real sobre as florestas globais, incluindo alertas de desmatamento e degradação florestal. Existem duas principais metodologias de alerta de desmatamento e degradação usadas no GFW: *Global Land Analysis and Discovery* (GLAD) e *Radar Alerts for Detecting Deforestation* (RADD).

O sistema de alerta GLAD utiliza imagens de satélite para rastrear dados semanais de desmatamento em toda a região tropical. O sistema analisa imagens dos

satélites Landsat 8 e Landsat 9 da NASA para identificar áreas onde a cobertura florestal foi perturbada, indicando potencial perda de árvores. Os alertas GLAD cobrem latitudes de 30 graus norte a 30 graus sul e são mais confiáveis na detecção de mudanças em áreas com pelo menos 60% de cobertura florestal. Os alertas são intencionalmente conservadores e priorizam a velocidade em vez da precisão, sendo que alertas não confirmados podem ser alterados por até seis meses. Os alertas GLAD visam fornecer uma indicação precoce de onde o desmatamento pode estar ocorrendo, permitindo ação direcionada por agentes de aplicação fiscalizadores, comunidades locais e organizações de defesa. No entanto, esse sistema não é recomendado para calcular a área de perda florestal, pois não tem alta precisão devido à priorização da velocidade e de falsos positivos (HANSEN *et al.*, 2013).

Já a metodologia do alerta RADD utiliza dados de radar para detectar mudanças na cobertura florestal. Os dados de radar são menos sensíveis a condições climáticas adversas, como nuvens, o que permite uma detecção mais precisa de mudanças na cobertura florestal. O alerta RADD usa imagens de radar de alta resolução do satélite Sentinel-1, que são processadas usando algoritmos para detectar mudanças significativas na cobertura florestal. Assim como os alertas GLAD, os alertas RADD são validados manualmente para garantir a precisão dos resultados (REICHE *et al.*, 2021)

O MapBiomás é uma iniciativa brasileira de monitoramento anual da cobertura e uso do solo, que produz mapas temáticos em média resolução espacial (30 metros), desde 1985 até o presente. O projeto é resultado da união de diferentes organizações e universidades brasileiras que atuam na área de sensoriamento remoto, processamento de imagens e análise de dados geoespaciais (MAPBIOMAS, 2020). O objetivo do MapBiomás é fornecer informações atualizadas sobre a dinâmica do uso da terra no Brasil, auxiliando no planejamento territorial, gestão ambiental e controle de desmatamento. Os mapas produzidos pelo projeto permitem uma análise das mudanças na cobertura e uso do solo, bem como a identificação de áreas de desmatamento, degradação ambiental e conservação da biodiversidade (MAPBIOMAS, 2020). Para produzir os mapas anuais, se utiliza de técnicas de processamento de imagens de satélite e algoritmos de classificação supervisionada e não supervisionada. Além disso, o projeto aplica filtros temporais e espaciais para reduzir a ocorrência de erros e artefatos nos mapas (MAPBIOMAS, 2020). Os resultados do projeto estão disponíveis gratuitamente para acesso e download no site

oficial, que também disponibiliza uma série de ferramentas e plataformas de análise de dados geoespaciais.

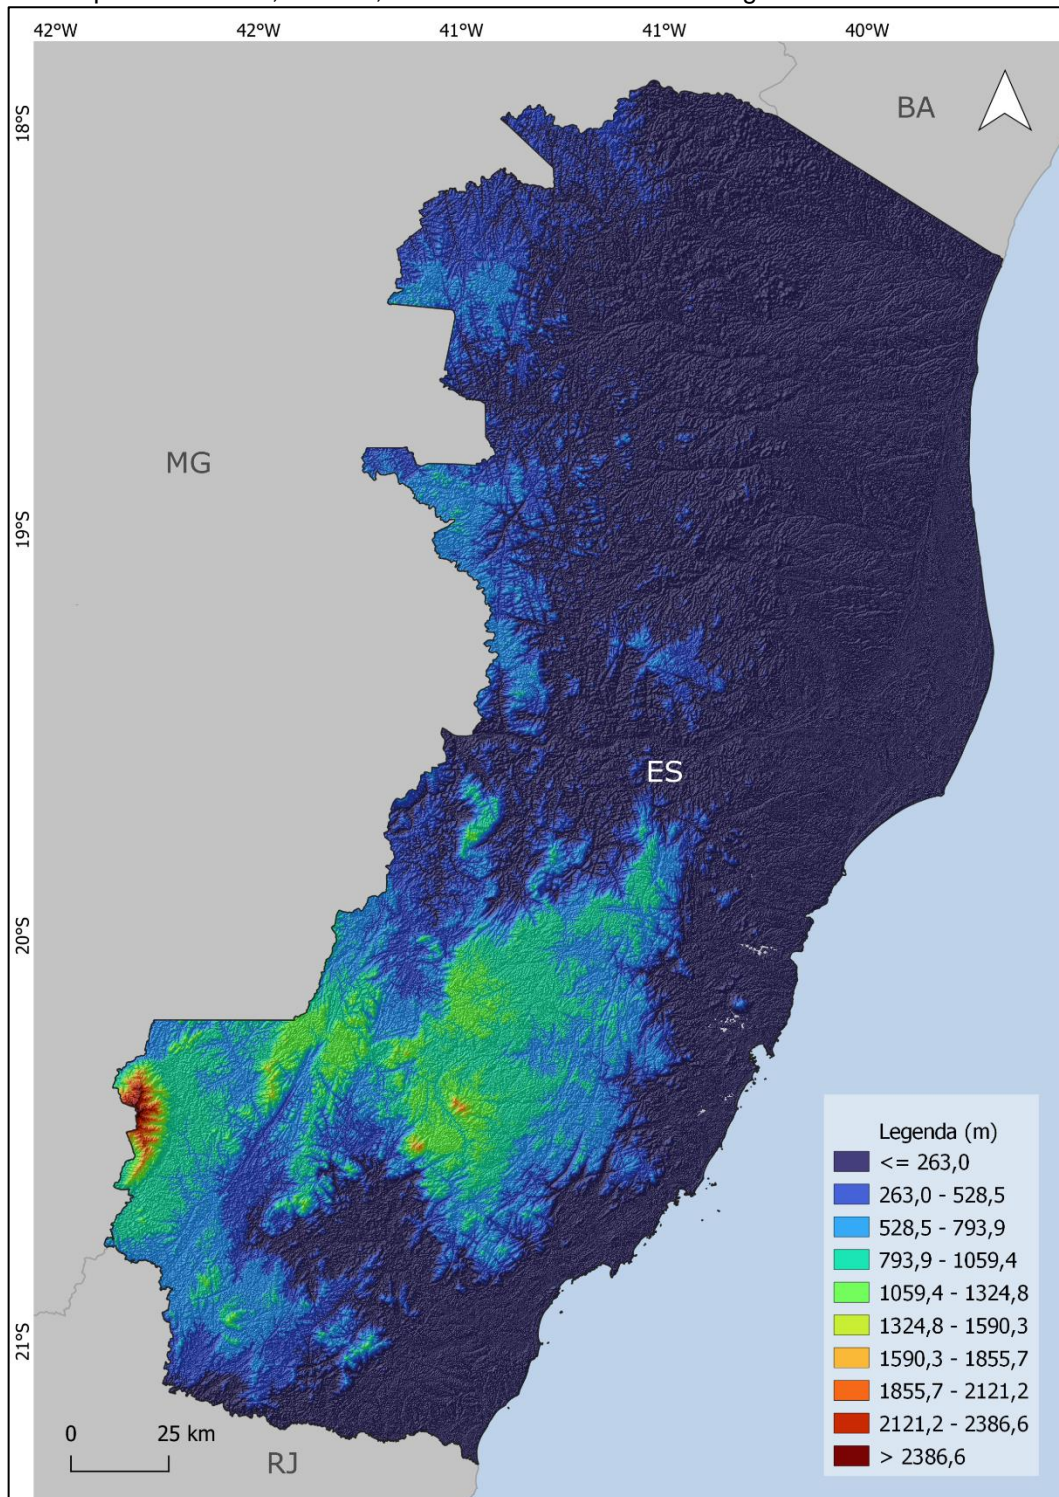
4 METODOLOGIA

4.1 ÁREA DE ESTUDO

A área de estudo compreendeu as áreas de plantio florestal com o gênero *Eucalyptus* do estado do Espírito Santo, que possui coordenada central de 19°16'59.50"S, 40°18'40.65"O. O estado possui aproximadamente 46 mil km² de área e população de mais de 4 milhões de habitantes (IBGE, 2010). O clima, em sua maioria, é classificado Aw (Köppen), tropical úmido, com temperatura média do ar varia entre 22 a 24°C. O regime de chuvas no estado várias conforme a região, entretanto varia entre 1.000 a 1.4000 mm (ALVARES, 2014).

O relevo é caracterizado em sua maioria como baixada litorânea, correspondendo a 40% do território, o estado conta também com uma região serrana localizada a sudoeste, fronteira com o estado de Minas Gerais. Já altimetria apresenta uma amplitude de zero (ao nível do mar) até 2.890m, ponto esse situado no Pico da Bandeira (Figura 1) (IBGE, 2009).

Figura 5 – Mapa hipsométrico do Estado do Espírito Santo. Utilizando dados SRTM, com escala de mapeamento de 1;250.000, Sistema de coordenadas Geográficas SIRGAS 2000.



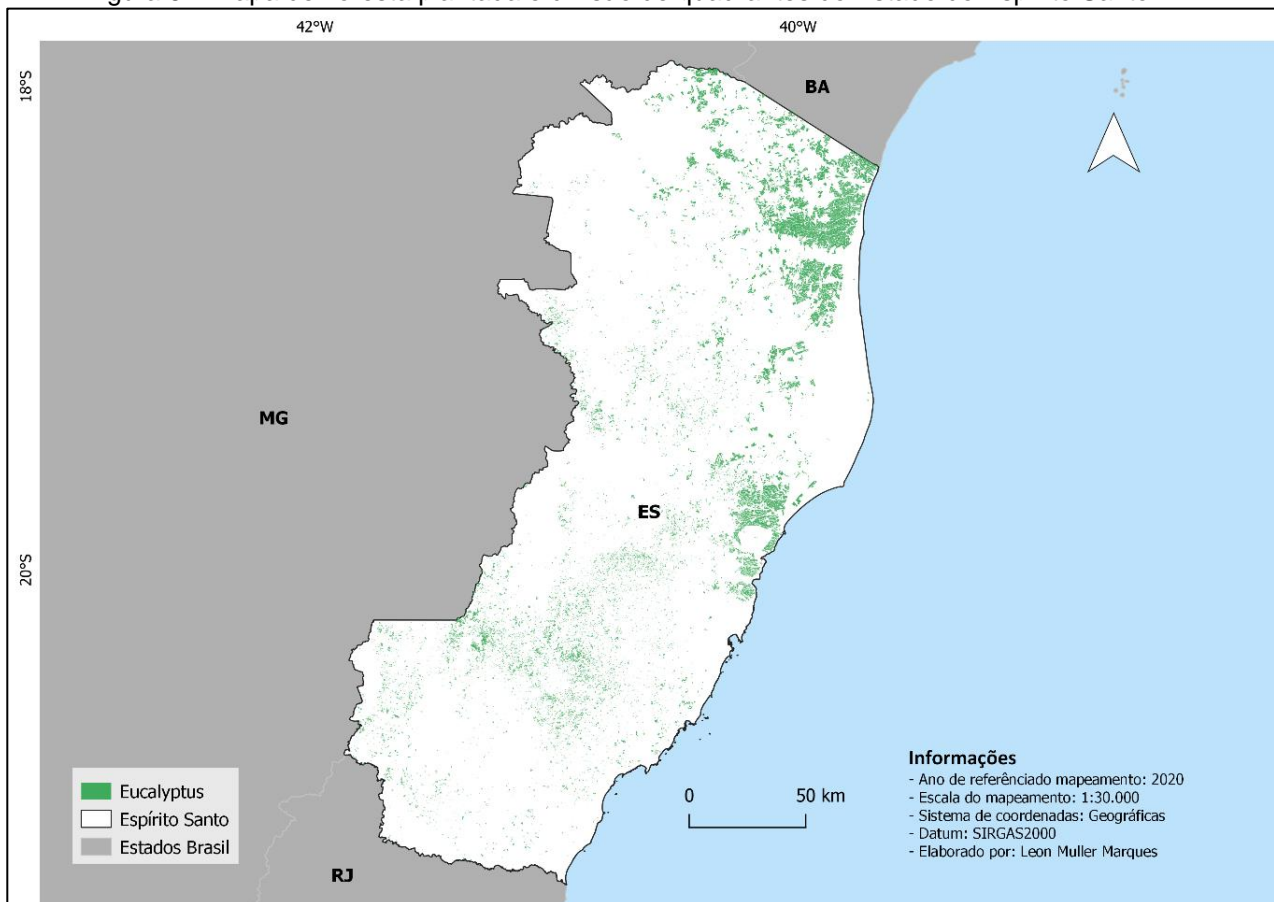
Fonte: Autor (2023).

4.2 BASE DE REFERÊNCIA DE FLORESTA PLANTADA NO ES

A fim de desenvolver um algoritmo para a detecção da colheita de plantações de eucalipto, é importante estabelecer, como ponto de partida, o conhecimento preciso da localização geográfica dos talhões dentro do estado do ES. Esta informação geoespacial é um pré-requisito fundamental, permitindo que as florestas sejam monitoradas individualmente e de forma sistemática.

A empresa *Canopy Remote Sensing Solutions* é especializada na geração de inteligência geográfica por meio da aplicação de tecnologia em estudos florestais. Entre seus produtos, destaca-se o *Canopy Insight*, que consiste em um mapeamento minucioso dos plantios de florestas em todo o território brasileiro, utilizando imagens de satélite. Ela disponibilizou os dados dos plantios de *Eucalyptus* para o estado do Espírito Santo (Figura 6) para o desenvolvimento desse estudo (<https://www.canopyrss.com.br>).

Figura 6 – Mapa de floresta plantada e divisão de quadrantes do Estado do Espírito Santo.




Fonte: Autor (2023).

4.2.1 Mapeamento de limites dos talhões de *Eucalyptus*

O mapeamento de limites abrange uma área total de aproximadamente 270 mil hectares de plantações, mapeadas com granularidade de talhão de no mínimo um quarto de hectare, e foi desenvolvida por meio da interpretação visual de imagens multiespectrais com resolução espacial de 20 metros, dentro de um Sistema de Informações Geográficas (SIG), mapeando todos os talhões que fossem visíveis numa escala de 1:30.000. As imagens empregadas no processo foram capturadas pelos satélites do programa Sentinel-2 nos anos de 2018, 2019 e 2020, e são disponibilizadas gratuitamente pela Agência Espacial Europeia. Essas imagens apresentam uma resolução radiométrica de 12 bits e contêm informações em 13 bandas espectrais, incluindo as faixas do espectro visível (RGB), infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR). Os dados foram adquiridos com um nível de processamento Level-2A (Figura 7), que inclui correções radiométricas, geométricas e atmosféricas.

Figura 7 – Florestas de *Eucalyptus* (coloração avermelhada) e nativas (coloração marrom) de uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red).



Fonte: Autor (2023).

Nas áreas com disponibilidade de imagens com maior resolução espacial do que a do Sentinel-2 (provedores da Google ou da ESRI), foi realizado um trabalho adicional de refinamento dos limites mapeados (Figura 8), editando os limites dos polígonos de *Eucalyptus* no SIG. Foi mapeado todos os alvos, identificado como *Eucalyptus* nas imagens do Sentinel-2, nos três anos analisados.

Para a avaliação da qualidade do mapeamento, no ano de 2021 foram coletados em campo 1.604 pontos de controle com *Global Positioning System* (GPS), que cobriram todas as regiões do estado, classificados em duas classes: a primeira foi de *Eucalyptus* e a segunda de não *Eucalyptus* (nessa classe inclui outras culturas, que podem ser confundidas com a classe de *Eucalyptus*) (Figura 9).

A análise da precisão do mapeamento foi conduzida analisando o coeficiente Kappa, que é uma medida frequentemente utilizada para avaliar a concordância entre as classificações obtidas por um modelo e os dados reais representados na matriz de confusão. Essa métrica oferece uma representação numérica da confiabilidade e precisão das classificações efetuadas (Amaral, 2009). O resultado do coeficiente Kappa reflete o grau de concordância entre as classificações do modelo e os dados reais, onde valores mais próximos de 1 indicam uma maior qualidade das classificações (Equação 5).

$$Kappa = \frac{P_0 + P_e}{1 - P_e} \quad (5)$$

em que:

P_0 : é a proporção de concordância observada entre as classificações reais e as previsões do modelo.

P_e : é a proporção de concordância esperada ao acaso.

Diversos índices são empregados para transformar dados quantitativos em qualitativos, sendo um deles destacado por Fonseca (2000) conforme apresentado na Tabela 1. Esta abordagem permite interpretar e contextualizar a confiabilidade das classificações realizadas, possibilitando uma análise mais abrangente do desempenho do modelo utilizado.

Tabela 1 – Classes 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

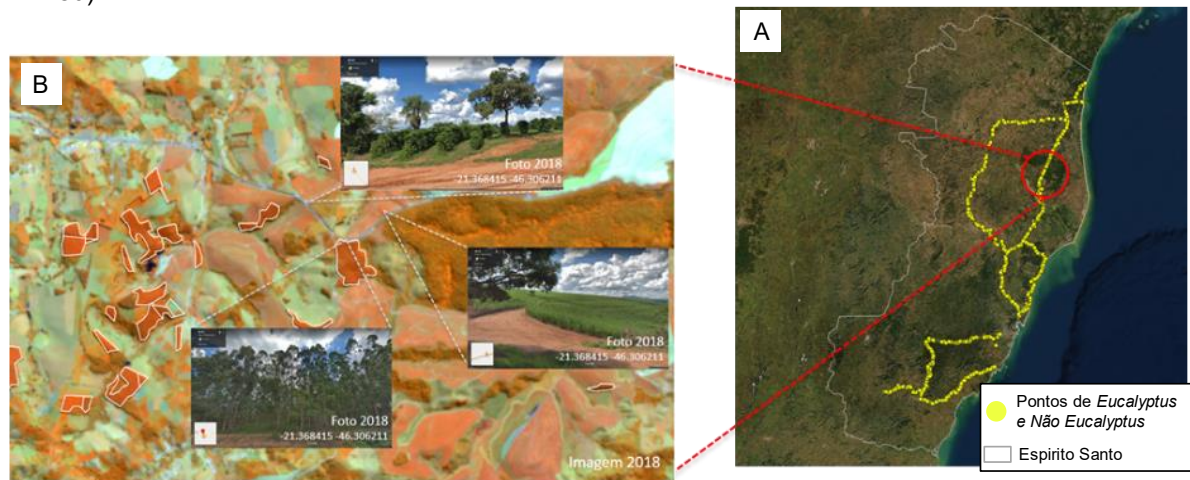
Fonte: Fonseca (2000).

Figura 8 – Detalhamento dos limites dos talhões mapeados sobre uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red), município de São Mateus-ES.



Fonte: Autor (2023).

Figura 9 – A) Localização dos pontos de controle do mapeamento coletado em campo. B) exemplo das classes dos pontos coletadas em campo sobre uma imagem Sentinel-2 (composição R: NIR, G:SWIR, B:Red).

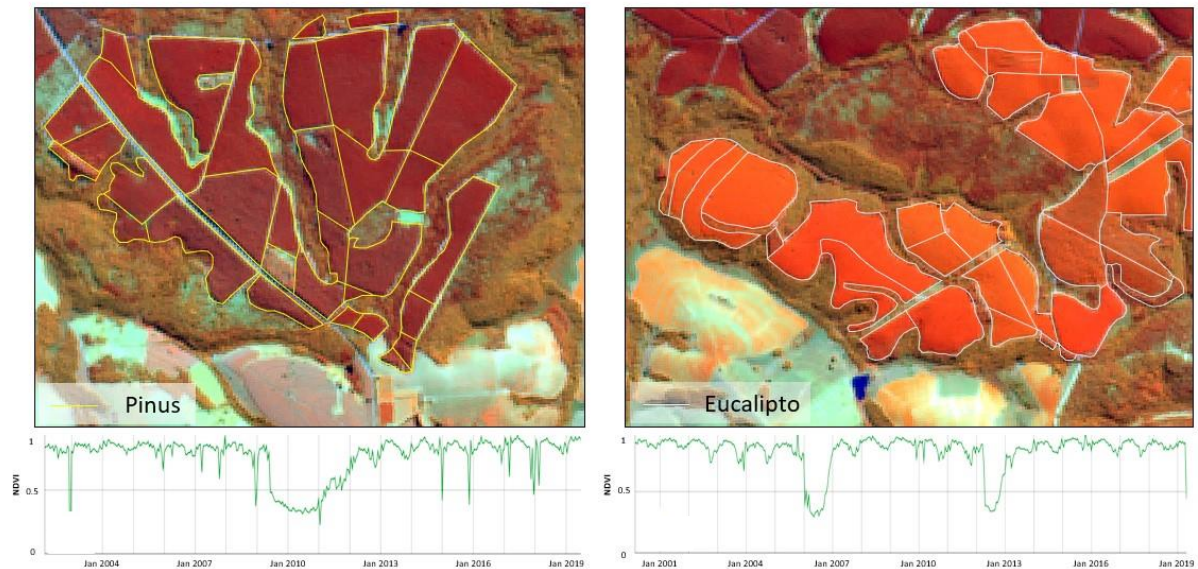


Fonte: Autor (2023).

4.2.2 Definição do gênero plantado

Para a identificação do gênero dos povoamentos florestais plantados foi realizada a interpretação visual de padrões de tonalidade, textura e contexto da área, identificados em composições coloridas (R = NIR, B = SWIR e G = Red) provenientes de séries temporais de imagens captadas pelo satélite Sentinel-2. Além disso, séries temporais de índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (NDVI), coletadas pelo sensor MODIS, foram utilizadas com o objetivo de aprimorar a precisão da classificação do gênero dos plantios, uma vez que esses índices fornecem informações sobre o desenvolvimento das culturas e a duração dos ciclos de colheita, como ilustrado na Figura 10.

Figura 10 – Ilustração dos padrões de tonalidade, textura e contexto observados nas imagens Sentinel-2 para a definição do gênero plantado. Os gráficos na porção inferior mostram séries temporais de um índice de vegetação (NDVI), utilizadas para descrever a velocidade de crescimento das florestas e a duração da rotação.



Fonte: Autor (2023).

Por fim, foi utilizado *Google Street View* (Figura 11) para auxiliar a classificação do gênero dos plantios florestais. Esta ferramenta permite a observação de fotos tirada por um automóvel do *Google*, do tipo de cultura presente no campo, e quando combinada com as demais ferramentas mencionadas, contribui para alcançar a maior precisão possível na classificação do gênero das plantações. Entretanto, essa ferramenta só pode ser utilizada perto de estradas e rodovias que a Google tenha coletado dados. Em estradas mais interioranas, geralmente essa ferramenta, não está disponível.

Figura 11 – Ilustração mostrando uma imagem do *Google Street View* de um plantio de *Eucalyptus*.



Fonte: Autor (2023).


4.2.3 Definição do dado de referência de colheita de povoamentos de *Eucalyptus*

Para a validação do algoritmo de colheita foi produzido um dado de referência em que cada talhão foi avaliado individualmente, a partir de uma série temporal de imagens trimestrais, iniciando no quarto trimestre (T4) de 2020 e regredindo cinco anos no tempo. A partir da inspeção visual da série temporal construída, foi definida a data da colheita dos talhões de *Eucalyptus*, com base na data da imagem analisada.

Essa análise foi feita visualmente, levando em consideração a resposta espectral das imagens. A determinação da idade foi realizada por meio de interpretação visual de imagens dos satélites Sentinel-2. Subsequentemente, essas imagens foram recortadas para se ajustarem às dimensões dos talhões. O procedimento adotado consistiu em dois passos principais: (i) a seleção da melhor imagem disponível para cada trimestre na série temporal de 10 anos, referente a cada talhão, com base na informação de porcentagem de nuvem da imagem, fornecida pela própria Agência Nacional Europeia e (ii) a análise da resposta espectro-temporal do talhão, que considera a data da colheita com base na primeira imagem em que se observa a presença de solo exposto (representado por coloração verde na imagem) mais recente após uma imagem que apresenta floresta (representado por coloração vermelha na imagem), levando em consideração a série temporal completa. Com base

na Figura 12, é possível verificar que a colheita deste talhão ocorreu durante o terceiro trimestre (T3) do ano de 2018 e replantado no primeiro trimestre (T1) de 2019.

Figura 12 – Ilustração da resposta espectral de um plantio de eucalipto ao longo de uma série temporal de cinco anos de imagens trimestrais Sentinel-2/Landsat (composição falsa-cor R8A-G11-B4).



Fonte: Autor (2023).

Foi definida visualmente a data de colheita de 32.832 polígonos. A fim de assegurar uma comparação equivalente entre a base de referência e as informações produzidas pelo algoritmo, procedeu-se à seleção na base exclusivamente dos polígonos referentes ao gênero *Eucalyptus* e aqueles que apresentam o registro de colheita no ano de 2019 e 2020. O resultado dessa seleção resultou em um conjunto total de 3.727 polígonos, que serviram para as análises do algoritmo.

4.3 PROCESSAMENTO DE IMAGENS

A abordagem técnica empregada no projeto para o processamento de imagens foi realizada na plataforma de processamento de imagens de satélite e análise geoespacial *Google Earth Engine* (GEE). A metodologia para validação dos algoritmos desenvolvidos foi realizada no ambiente de programação R versão 4.2.2 (R Core Team, 2021). Nas subseções seguintes é fornecida uma descrição detalhada dos métodos empregados em cada etapa.

4.3.1 Aplicação do algoritmo Sen2cor

O Sen2Cor é um algoritmo para correção dos produtos Sentinel-2 Level-1C, com o objetivo de fornecer um produto de reflectância de superfície Level-2A. A saída do Level-2A (L2A) consiste em uma imagem de Classificação de Cena (SCL) com onze classes, juntamente com indicadores de qualidade para probabilidades de nuvens e neve, mapas de Espessura Ótica de Aerossol e Vapor de Água, além de imagens de reflectância de superfície (BOA). Na Tabela 2 estão apresentadas as onze classes com suas respectivas representações de cores na banda SCL.

Tabela 2 – Lista de classes de classificação de cena (SCL) do Sen2Cor e cores correspondentes

No.	Classe	Cor
0	Sem dados	
1	Pixel saturado ou com defeito	
2	Objetos escuros / Sombras	
3	Sombra de nuvem	
4	Vegetação	
5	Solos / Desertos	
6	Água	
7	Probabilidade baixa de nuvem	
8	Probabilidade média de nuvem	
9	Probabilidade alta de nuvem	
10	Cirrus	
11	Neve ou gelo	

Fonte: ESA (2015)

A metodologia de classificação de cada classe é apresentada a seguir.

a) Nuvem e neve

O algoritmo de detecção de nuvens/neve realiza seis testes, utilizando diferentes bandas e álgebras de bandas, resultando em uma probabilidade de nuvem para cada pixel (variando de 0 para céu claro com alta confiança a 1 para céu nublado com alta confiança). Após cada etapa, a probabilidade de ocorrer nuvem de um pixel potencialmente nublado é atualizada multiplicando a probabilidade de nuvem atual do pixel pelo resultado do teste.

O processo de detecção de neve segue a mesma abordagem com cinco testes distintos, resultando em 0 para alta confiança de céu limpo (sem neve) a 1 para pixel com alta confiança para presença de neve. Este procedimento representa uma estratégia sistemática de avaliação da probabilidade de nuvem e neve em cada pixel da imagem, permitindo uma classificação do estado atmosférico e de cobertura de neve na imagem de satélite.

b) Vegetação e solo

Para a identificação de pixels de vegetação foram empregues duas aritméticas entre bandas: o NDVI (Equação 2) e uma razão de reflectância entre as bandas NIR e Verde resultando no IR (Equação 6). Foram estabelecidos limiares de 0,40 e 2,50 para o NDVI e IR, respectivamente. Quando os valores de NDVI e IR excedem estes limiares, o pixel é classificado como vegetação. Já quando o pixel apresenta valores abaixo de um limiar de IR igual a 0,55 ele é classificado como solo exposto.

$$IR = \frac{NIR}{GREEN} \quad (6)$$

c) Água, cirros e sombra de nuvem

Para a classificar o pixel como água, a razão da reflectância R_B (Equação 7) deve ultrapassar o limiar de R_B igual a 4,0.

$$R_B = \frac{BLUE}{SWIR} \quad (7)$$

Para a classificação de cirros finos, foi utilizado um limiar de reflectância da banda 10 (B10) do Sentinel-2. No primeiro passo, todos os pixels B10 com um valor de R_B entre 0,012 e 0,035 foram considerados como cirros finos. No segundo passo, após a geração de uma máscara probabilística de nuvem, o pixel foi classificado como um cirro fino se a probabilidade de nuvem estiver menor ou igual a 0,35.

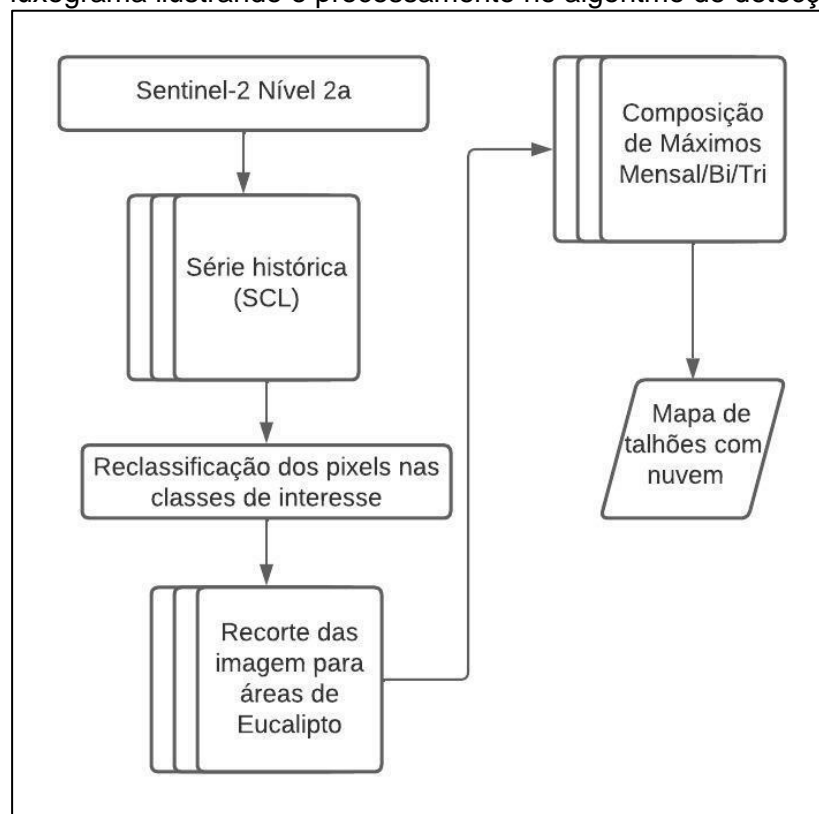
A máscara de sombra de nuvem foi construída pela multiplicação de duas componentes distintas. Em primeiro lugar, as sombras de nuvem "geometricamente

prováveis" foram derivadas com base na máscara final de nuvem, na posição solar e na distribuição altimétrica das nuvens. Em segundo lugar, as sombras de nuvem "radiometricamente prováveis" foram obtidas por meio da classificação das "áreas escuras" por uma rede neural (RAIYANI, 2021).

4.4 AVALIAÇÃO DO DADO DE NUVEM

Uma etapa crucial para a calibração do algoritmo de detecção de áreas colhidas é a realização de uma análise de qualidade das imagens do Sentinel-2 (Figura 13). Como as imagens que servem de base para o algoritmo são ópticas, a presença de nuvens pode influenciar na qualidade do resultado e causar a ausência de informações nas áreas afetadas por nuvens.

Figura 13 – Fluxograma ilustrando o processamento no algoritmo de detecção de nuvem.



Fonte: Autor (2023).

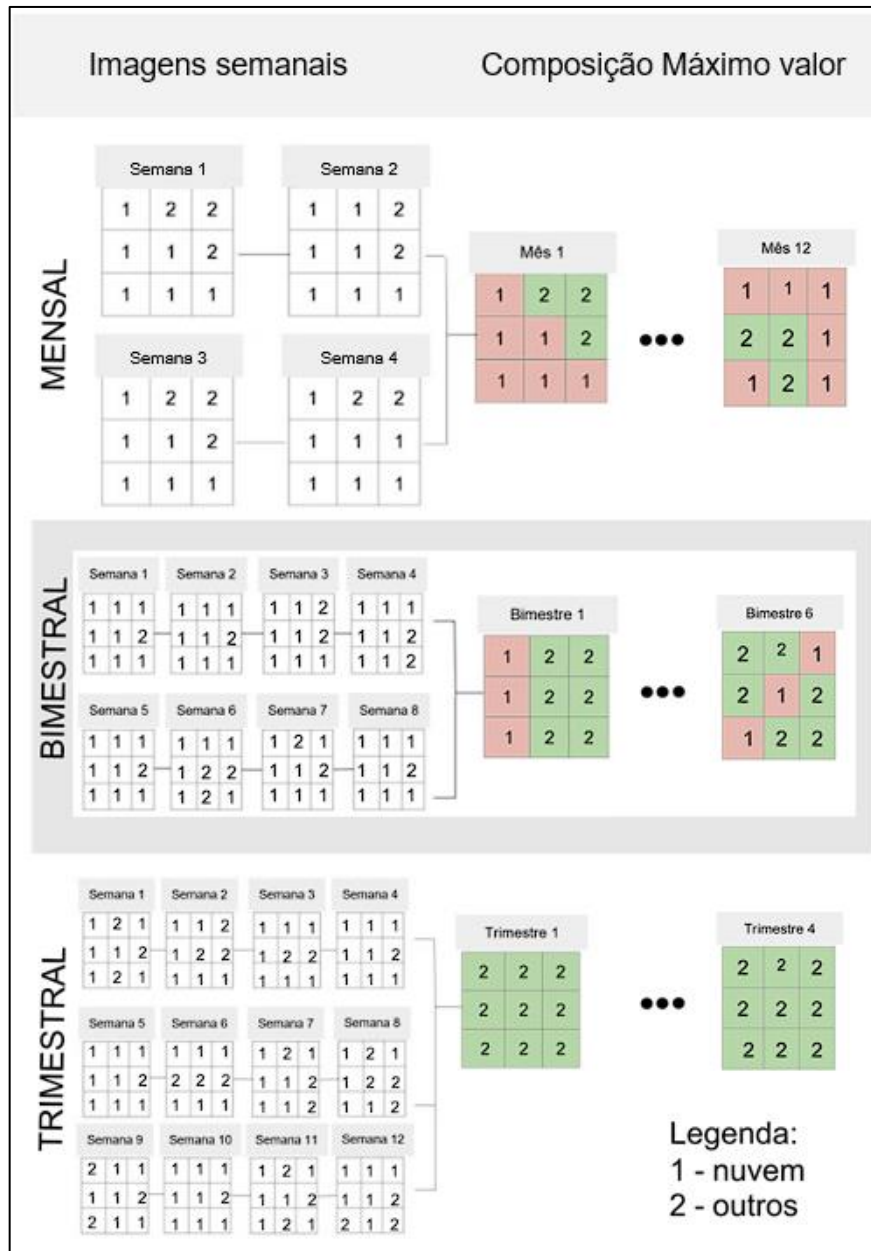
No Espírito Santo, devido ao clima quente e chuvoso durante os meses de agosto a fevereiro, há uma alta incidência de nuvens. Para avaliar o impacto dessa incidência de nuvens nas análises foram utilizadas as informações do algoritmo de

classificação de imagem da coleção do Sentinel-2 nível 2a o SCL, no período de janeiro a dezembro de 2020.

Após juntar as imagens, o próximo passo consistiu em reclassificar as classes SCL das imagens Sentinel-2A, atribuindo o valor 1 às classes relacionadas a nuvens ou sombras (0, 1, 2, 3, 7, 8, 9, 10 e 11) e o valor 2 às demais classes (4, 6 e 7). Em seguida, a série histórica de imagens reclassificadas foi recortada para cada talhão de eucalipto. A partir dessa reclassificação, foram consideradas as categorias temporais mensal, bimestral e trimestral, levando em conta a duração das épocas chuvosas no Espírito Santo. O objetivo foi avaliar qual categoria apresenta a menor contaminação por nuvens nos talhões monitorados.

Para agregar as imagens do Sentinel-2 nas categorias temporais, os dados de sensoriamento remoto foram compilados. Para isso, as imagens para o período desejado (janeiro a dezembro de 2020) foram filtradas. Em seguida, foi aplicado um processo de agregação temporal, identificando o valor máximo de cada pixel das imagens, e construindo imagens do mês/bimestre/trimestre. Isso é feito iterativamente, atualizando o valor máximo sempre que um valor superior é encontrado para um pixel específico. Como pode ser observado na Figura 14, as imagens geradas é uma composição dos pixels de máximo do mês/bimestre/trimestre e, isso é repetido para cada intervalo de tempo. O resultado é uma única imagem em que cada pixel representa o valor máximo registrado durante o período selecionado, oferecendo uma visão consolidada das características geoespaciais monitoradas, naquele mês, bimestre ou trimestre.

Figura 14 – Esquema sintetizando a construção das imagens de máximo mensais, bimestrais e trimestrais.



Fonte: Autor (2023).

A avaliação das nuvens nas três classes temporais (mensal, bimestral e trimestral) buscou evitar a seleção de uma classe temporal com cobertura de nuvens superior a 30% dentro do talhão. Foi selecionado este valor porque uma cobertura alta de nuvens pode resultar em uma porção significativa do talhão não sendo observada, o que, por sua vez, pode levar não detecção da colheita do talhão e, conseqüentemente, diminuir a acurácia do algoritmo.

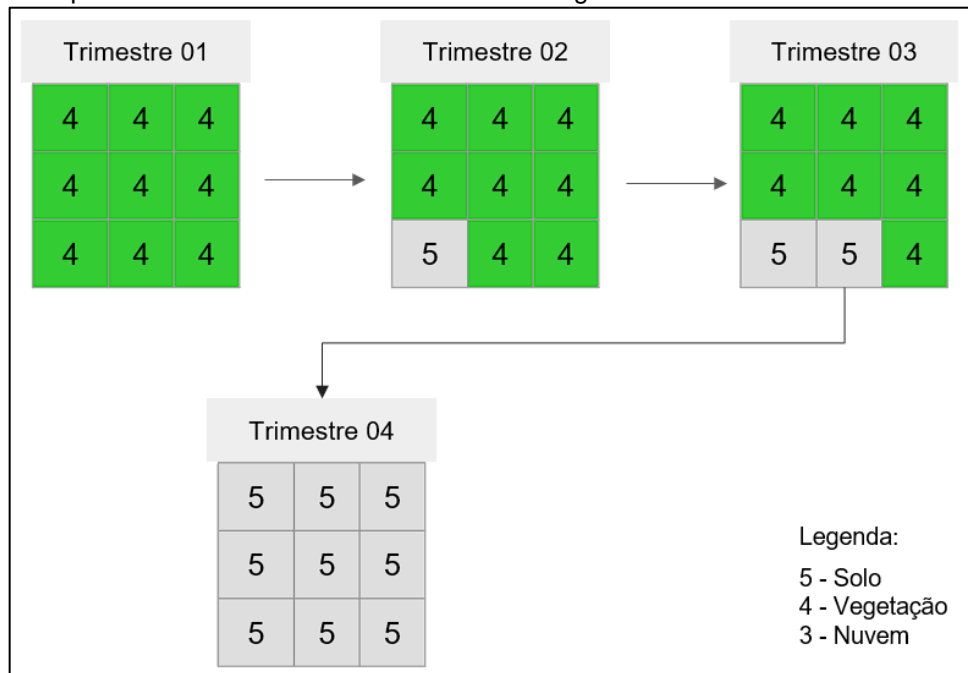
4.5 DETECÇÃO AUTOMÁTICA DE ÁREAS COLHIDAS

Para a detecção de áreas colhidas no estado do Espírito Santo foi considerado apenas o ano de 2020. O algoritmo desenvolvido para a detecção automática de colheita nos talhões de floresta de *Eucalyptus* é baseado na classificação de imagens gratuitas coletadas pelos satélites Sentinel-2, no produto denominado de SCL. Com a análise de nuvem realizada, é possível definir qual é a categoria temporal (mensal, bimestral ou trimestral) que vai trazer as imagens com menor porcentagem de nuvem por polígono de *Eucalyptus*. Essa metodologia pode ser aplicada para qualquer categoria temporal. Caso seja aplicado em áreas diferentes, a análise de nuvem que vai definir o intervalo temporal do monitoramento.

O primeiro passo para detecção, assim como na análise de nuvem, foi baixar a série histórica de imagens SCL, para o estado do Espírito Santo. Entretanto, o passo de reclassificação das classes do SCL, para o desenvolvimento do algoritmo de colheita, tem algumas particularidades. Foi atribuído o valor três às classes relacionadas a nuvens, sombra e água (0, 1, 2, 3, 7, 8, 9, 10 e 11), o valor quatro para a classe floresta e o valor cinco para a classe solo. A partir dessa reclassificação, as imagens foram recortadas para o limite do talhão de *Eucalyptus* fornecido pela base da empresa Canopy. Isso resultou em uma imagem com as dimensões dos polígonos e classificada em Floresta, Solo e Nuvem.

Por fim, selecionada a categoria temporal, as imagens semanais foram agregadas ao intervalo desta categoria, com base no valor de máximo reclassificação. Portanto, em um conjunto de imagens semanais, o valor de solo que é a classe 5 sempre irá se sobrepor as outras classes, garantindo que na composição para gerar a imagens de máximos, o pixel de solo exposto sempre seja computado como demonstrado na Figura 15.

Figura 15 – Esquema resumindo o acúmulo do solo ao longo dos trimestres de um talhão de Eucalipto.



Fonte: Autor (2023).

As imagens foram recortadas com base no tamanho dos talhões, o que permitiu obter dados como o número de talhões colhidos e a porcentagem de cada talhão que foi colhida. E, uma vez que os talhões foram georreferenciados, pôde-se identificar a localização das áreas florestais colhidas e realizar análises espaciais levando em consideração os municípios, microrregiões e quaisquer limites políticos relevantes.

Para identificar a colheita ainda foi definido um limiar, por meio da experimentação, de quando considerar o talhão colhido, ou seja, qual a porcentagem de solo dentro do talhão para emitir o alerta de colheita.

4.6 Análise do algoritmo de colheita de povoamentos de *Eucalyptus*

Como o resultado do algoritmo indica a colheita florestal, o processo de análise dos resultados levou em consideração a porcentagem da área colhida do talhão. Para isso, a porcentagem de solo do talhão foi obtida a partir do número total de pixel. Esse processo foi feito para todos os meses, bimestres ou trimestres em cada talhão.

Para a avaliação do desempenho do algoritmo, foi realizada uma comparação direta entre o mês/bimestre/trimestre dos valores de porcentagem de solo com a data de colheita da referência, produzida por interpretação visual, descrito no item

4.2.3. Para definir o valor com a melhor acurácia, foi realizada uma análise gráfica, onde se buscou encontrar um valor com alta acurácia, e que leva em conta as características de como a colheita é realizada em campo, e as limitações do dado de sensoriamento remoto.

Para cada intervalo de porcentagem de área colhida foram selecionados e comparados com o mês/bimestre/trimestre de colheita da referência. Ainda, foi avaliada a acurácia em duas estratégias:

- Estratégia 1: Quando a colheita foi detectada exatamente no ano e no mês/bimestre/trimestre da colheita de *Eucalyptus* detectada pela referência.
- Estratégia 2: Quando a colheita foi detectada no mês/bimestre/trimestre anterior ou após a colheita de *Eucalyptus* detectada pela referência.

A Estratégia 2 foi traçada no intuito de minimizar os efeitos da metodologia proposta para a aquisição do dado de referência, que para identificar a colheita, escolhe a imagem mais livre de nuvem, e sempre tentando chegar no meio do trimestre, ou seja, a imagem é construída por uma única data. Já o algoritmo leva em consideração todos os pixels de solo exposto durante a composição de máximos da imagem, construindo assim uma imagem com os pixels de diversas datas, fazendo com que o algoritmo indique antes a colheita que a referência.

4.7 Análise da influência da declividade e do tamanho de talhão na detecção da colheita de povoamentos de *Eucalyptus*

Inicialmente, definido o limiar para considerar o talhão colhido com base na análise de dados, foi selecionado apenas os dados de colheita do ano de 2020. Em seguida, os talhões foram divididos em classes de tamanho e, também, em classes de declividade. Para cada categoria de tamanho e declividade, as taxas de erro e acerto foram obtidas. As porcentagens de erro e acerto foram calculadas dividindo o número de tamanho de polígono e declividade corretamente classificadas pelo número total de áreas na classe. Isso resultou nas porcentagens de acerto e erro para cada intervalo de tamanho e declividade.

5 RESULTADO E DISCUSSÕES

5.1 Validação do mapeamento das áreas de floresta plantadas de *Eucalyptus* no Espírito Santo

Na Tabela 3 é apresentada a matriz de erros obtida a partir da análise de 1.605 pontos amostrais, coletados por GPS em campo. Na diagonal principal da tabela é apresentado o número de amostras classificadas corretamente em cada classe.

Tabela 3 – Matriz de erros obtidas com a avaliação de 1605 pontos de controle obtidos em campo utilizando o GPS

		Campo		
		<i>Eucalyptus</i>	Não <i>Eucalyptus</i>	Total
Mapa	<i>Eucalyptus</i>	450	8	458
	Não <i>Eucalyptus</i>	95	1052	1147
	Total	545	1060	1605

Fonte: elaborado pelo autor

O coeficiente *Kappa* calculado para a matriz de confusão fornecida é aproximadamente 0,8516. Este valor, conforme Fonseca (2000), é classificado como “Excelente”, evidenciando um grau considerável de concordância entre as classificações reais e as previsões do modelo de classificação utilizado. Já a exatidão global, foi 93,55%, o erro de omissão de aproximadamente 8,27%, e o erro de comissão de aproximadamente 1,76%. Esses valores indicam baixas taxas de omissão e comissão das classes e é classificado como excelente, segundo proposto na literatura por (AMARAL *et al.*, 2009).

5.2 Análise da presença de nuvens nas imagens Sentinel-2 do Espírito Santo

Na Figura 16 são apresentados gráficos para os três intervalos de tempo em análise (mensal, bimestral e trimestral), com a distribuição das classes de porcentagem de nuvem dentro dos talhões, para datas de aquisição das imagens de composição de máximo. Analisando essa figura, pode-se observar que nas imagens das composições mensais e bimestrais há polígonos com mais de 30% de nuvem em vários períodos, principalmente nos meses mais úmidos do estado do Espírito Santo.

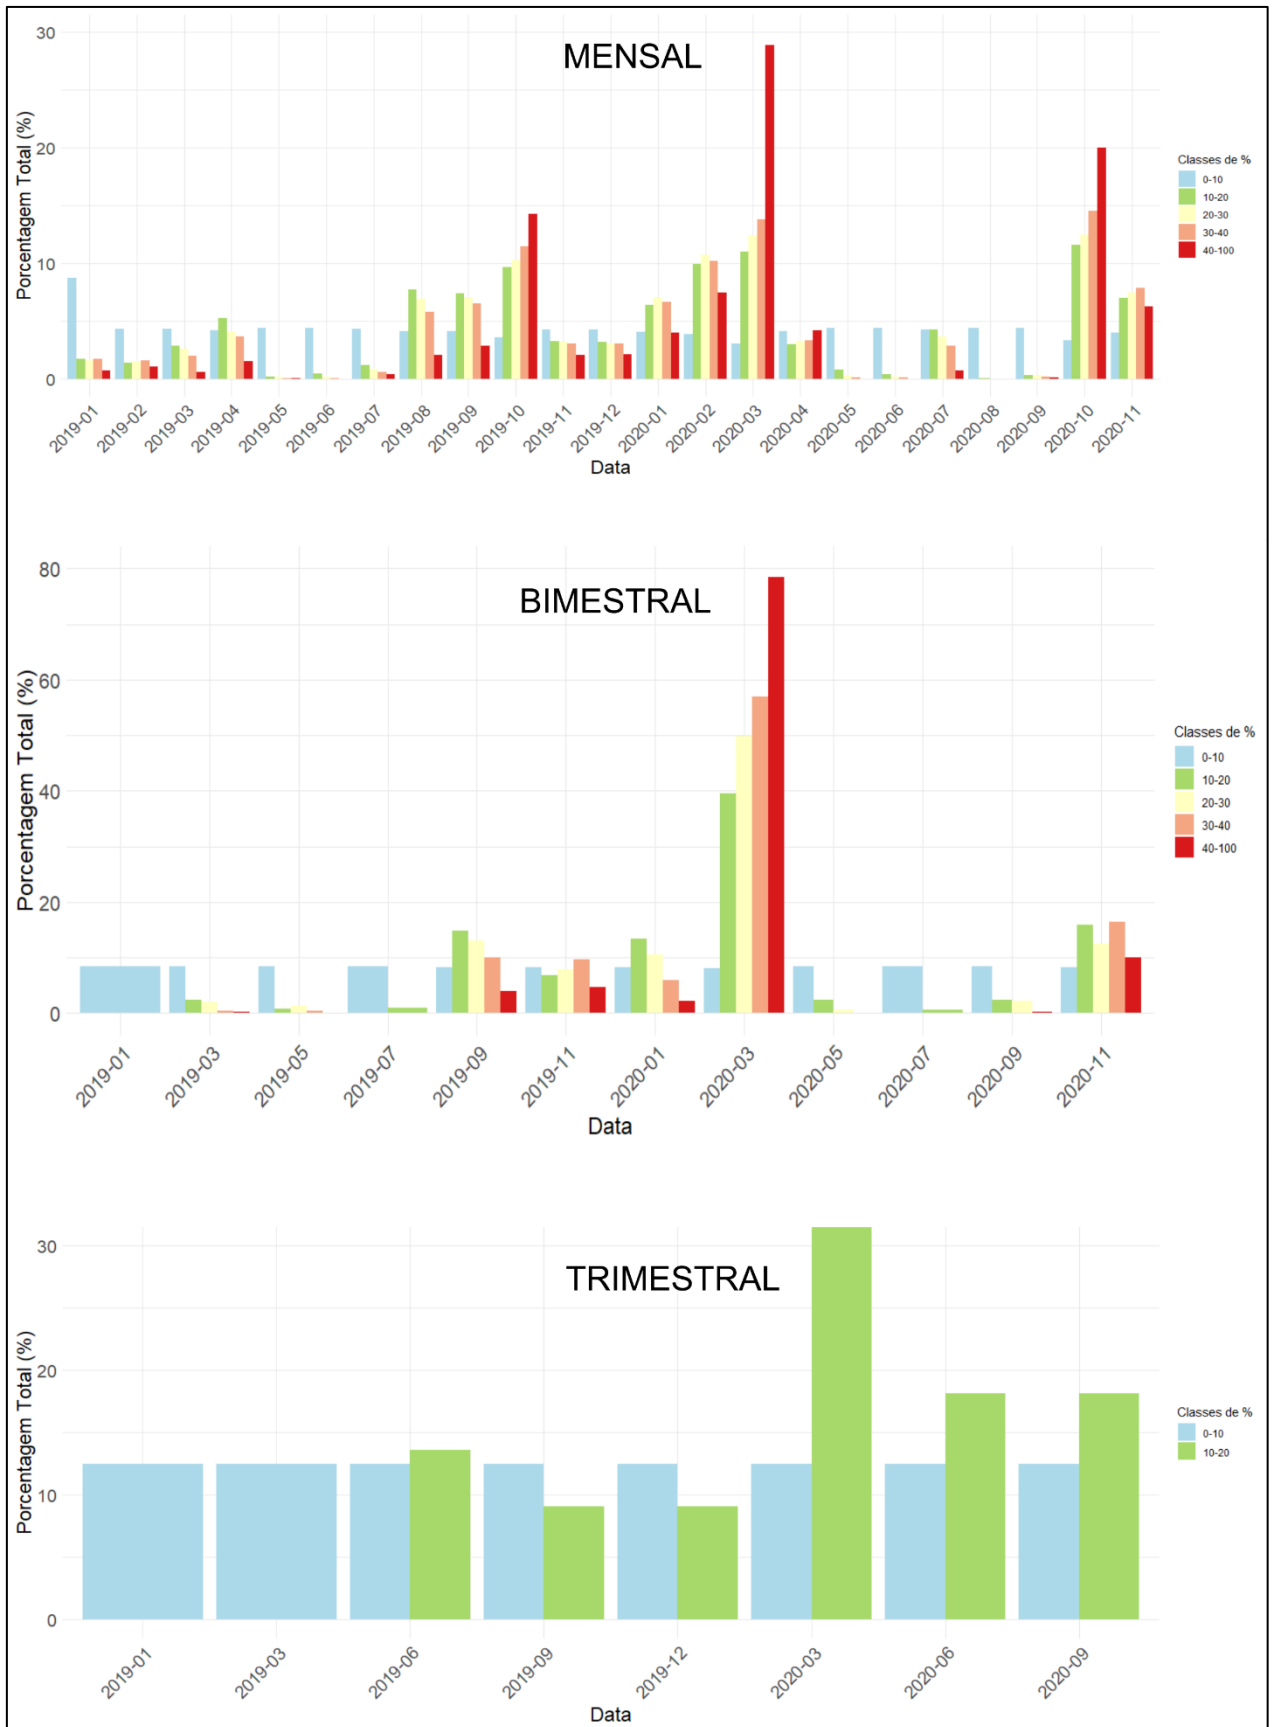
Já as composições de imagens trimestrais, não apresentam talhões de eucalipto com mais de 30% de nuvem.

O intervalo mensal tem o pior desempenho entre todos os analisados. Neste intervalo, 60% dos dados mensais estão contaminados com mais de 40% de presença de nuvem no talhão, comprometendo o funcionamento adequado do algoritmo. A escassez de imagens para a agregação, ocorre devido ao fato de que a imagem máxima do intervalo mensal é composta apenas por quatro imagens Sentinel-2, reduzindo as chances de obter pixels livres de nuvens para a construção da imagem de composição de máximos. Isso resulta em valores elevados de nuvens nos talhões.

O intervalo bimestral apresenta seis bimestres (48% do total) com polígonos que tem mais de 30% de cobertura de nuvens nos talhões. A melhora do resultado do intervalo bimestral, se dá pelo fato de que, para a composição da imagem de máximo bimestral, utilizou-se de oito imagens Sentinel-2. Com isso, o aumento do número de imagens para a agregação reduz a chance de o pixel ser coberto por nuvem. Entretanto, a presença de talhões com mais de 30% de nuvem, mesmo sendo melhor que o intervalo mensal, diminuiu consideravelmente a acurácia do algoritmo de detecção de colheita.

O intervalo trimestral tem talhões com cobertura de nuvens apenas nas duas primeiras classes estudadas (0 a 10% e 10 a 20%). A baixa incidência de nuvem nos talhões se dá pelo fato da composição trimestral de máximos, ser gerada com doze imagens Sentinel-2. Esse fato aumentou a chance de encontrar pixels não cobertos por nuvem, gerando imagens trimestrais com pouca incidência de nuvens. Assim, optou-se por trabalhar com escala trimestral, para minimizar a quantidade de área não observada devido à intensa cobertura de nuvens (risco de falsos negativos).

Figura 16 – Distribuição de frequência de talhões (%) por classe de nuvem dentro de cada talhão em diferentes períodos temporais.

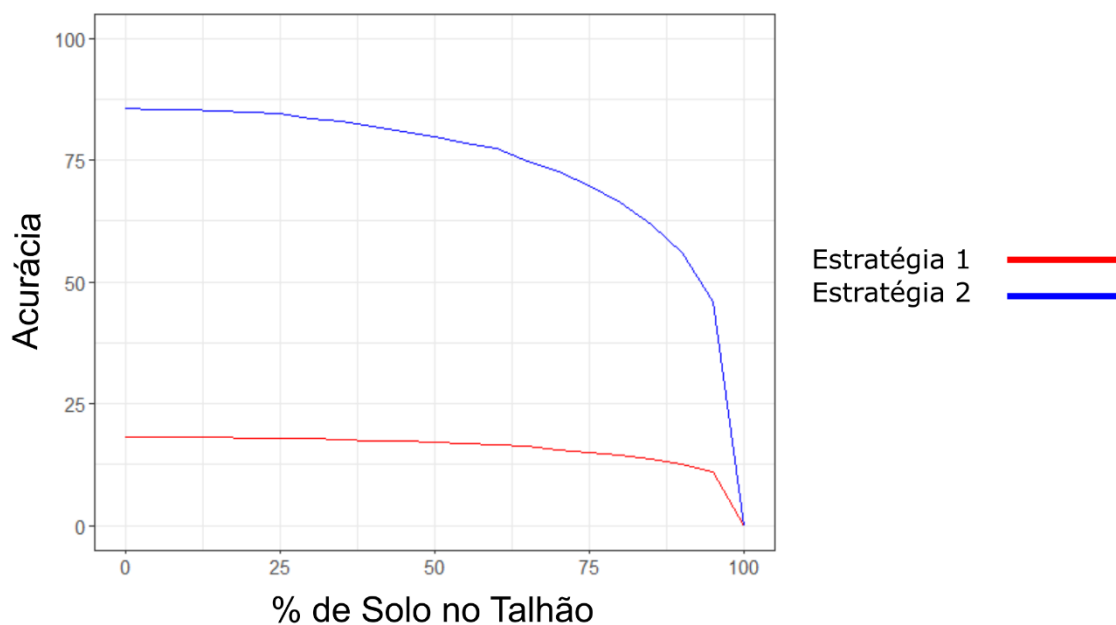


Fonte: Autor (2023).

5.3 Algoritmo de colheita florestal de povoamentos de *Eucalyptus*

Os resultados de acurácia do algoritmo de detecção de colheita florestal em função da porcentagem de solo colhido (limiar), na escala trimestral, para cada estratégia analisada podem ser observados na Figura 17.

Figura 17 – Acurácia da detecção em função da porcentagem de solo do talhão comparado com a referência em campo.



Fonte: Autor (2023).

A Estratègia 1, que é a detecção da colheita exatamente no trimestre de referência, se mostrou ineficiente. Essa estratégia gerou resultados de acurácia abaixo de 25% para todos os valores de porcentagem de solo. Esse baixo valor de acurácia é explicado pelo fato de que o algoritmo identifica a colheita antes da referência, fazendo com que o algoritmo tenha acurácia reduzida. Já na Estratègia 2, que é detecção da colheita em um trimestre anterior ou posterior ao trimestre da colheita da referência, a acurácia foi acima de 80% para diversos valores de porcentagem de solo exposto. Nota-se que à medida que aumenta o valor de solo no polígono para gerar o alerta de colheita, há uma redução da acurácia. Essa redução é explicada pelo efeito dos pixels de borda, que podem se manter com a classe floresta por muito tempo, impedindo que o talhão atinja altos valores de solo

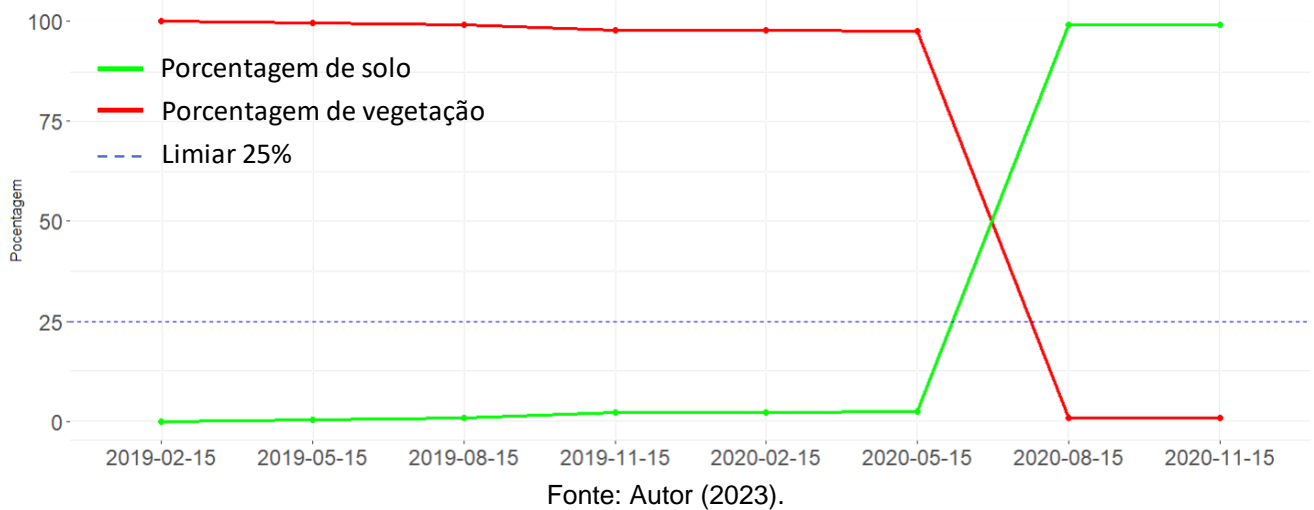
classificado pelo algoritmo, ou que ele atinja apenas quando a área adjacente seja colhida.

Segundo Bertin (2010), uma colheita com o Feller-Buncher pode abater um total de 400 árvores de eucalipto por hora. Considerando um dia de trabalho, pode-se inferir que uma máquina colhe pelo menos três hectares. Portanto, quando a colheita se inicia em um determinado talhão, as árvores tendem a serem colhidas no mesmo dia ou semana. Levando em consideração essas informações, não é necessário que a porcentagem de solo no talhão chegue a valores muito altos para considerar colhido, pois como se observa nos resultados (Figura 17), quanto mais alto valor de solo no pixel menor é a acurácia.

Para esse trabalho foi considerado um limiar maior que 25% para já considerar o talhão colhido e emitir o alerta, pois nesse limiar a acurácia foi de 84,5%. Nesse limiar há um menor efeito dos pixels de borda, e há uma acurácia elevada. As demais análises foram feitas utilizando esse limiar, tanto a de acurácia de área dos talhões quanto da de declividade do terreno.

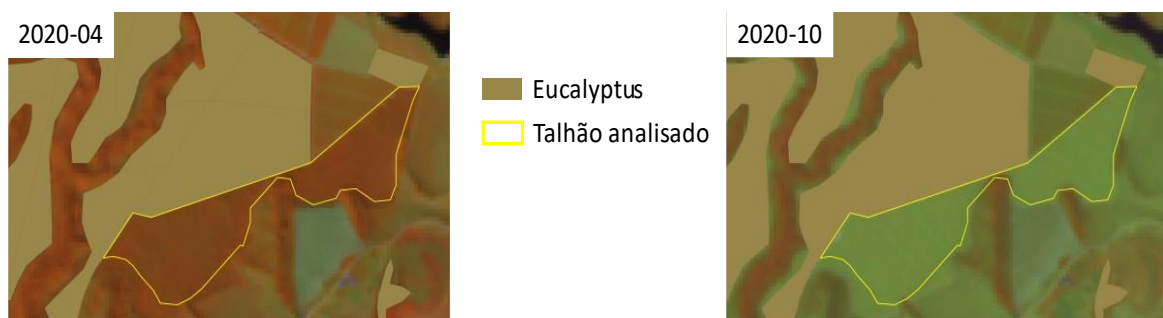
Na Figura 18, é possível observar a evolução de um talhão de *Eucalyptus* ao longo dos trimestres. No eixo y tem-se as porcentagens de cada classe dentro do talhão e no eixo x as datas do meio dos trimestres em análise. A linha vermelha refere-se a porcentagem dos pixels classificados como vegetação (PV) dentro do talhão e a linha verde é a porcentagem de pixels classificados como solo (PS) dentro do mesmo talhão. A linha azul é o limiar de solo, para considerarmos se o talhão foi colhido ou não, no caso definido como 25% ou seja, caso o PS ultrapassar 25% o talhão é considerado como colhido. Nesse exemplo (Figura 18) a colheita ocorreu no segundo trimestre de 2020, onde o PV estava em 100% e o PS em 0% para o terceiro trimestre de 2020, onde o PV foi para 0% e o PS para 100%.

Figura 18 – Gráfico da porcentagem de floresta (PV) e de solo (PS), de um polígono colhido, ao longo dos trimestres, até acontecer uma colheita.



Na Figura 19 tem-se as imagens da evolução do talhão apresentado na Figura 18. Foram utilizadas duas imagens RGB Sentinel-2, uma do segundo trimestre de 2020 e outra do terceiro trimestre de 2020, para demonstrar a realização da colheita florestal. Analisando essa figura, nota-se que no segundo trimestre há a presença de floresta no talhão, e no terceiro trimestre essa floresta estava totalmente colhida.

Figura 19 – Mapa do desempenho do algoritmo por mesorregião



5.4 Análise do efeito do relevo e tamanho de polígono na acurácia do algoritmo de detecção de colheita

A relação entre a classe de declividade do terreno, expressa em graus ($^{\circ}$), e as taxas de erro e acerto do algoritmo de detecção de colheita de povoamentos de *Eucalyptus*, considerando o limiar de solo maior de 25% é apresentada na Tabela 4.

Tabela 4 – Relação entre declividade do terreno e acurácia da detecção de colheita de povoamentos de *Eucalyptus*

Classe Declividade (°)	Erro		Acerto		Total
	Frequência	%	Frequência	%	
[0;5)	100	10,8	824	89,2	924
[5;10)	34	9,7	315	90,3	349
[10;15)	42	17,6	196	82,4	238
[15;20)	51	23,7	164	76,3	215
[20;25)	52	23,3	171	76,7	223
[25;30)	39	28,5	98	71,5	137
[30;50)	14	27,5	37	72,5	51

Fonte: elaborado pelo autor

Analisando os resultados, percebe-se que à medida que a inclinação do terreno aumenta, a acurácia da detecção diminui. Isso pode ser explicado pelo fato de que em superfícies mais inclinadas há o bloqueio dos raios solares, fazendo sombra nos objetos de interesse, mudando assim a resposta espectral (HORNING, 2010).

Na Tabela 5 é apresentada a relação entre a classe de tamanho dos talhões, e as taxas de erro e acerto do algoritmo de detecção de colheita de povoamentos de *Eucalyptus*.

Tabela 5 – Acurácia da detecção de colheita de povoamentos de *Eucalyptus* em função do tamanho dos talhões (ha).

Classe Área (ha)	Erro		Acerto		Total
	Frequência	%	Frequência	%	
[0;2.5)	115	21,9	410	78,1	525
[2.5;5)	95	19,7	388	80,3	483
[5;10)	57	12,2	412	87,8	469
[10;15)	35	15,1	197	84,9	232
[15;20)	11	6,9	149	93,1	160
[20;30)	7	4,6	145	95,4	152
[30;150)	12	10,3	104	89,7	116

Fonte: elaborado pelo autor

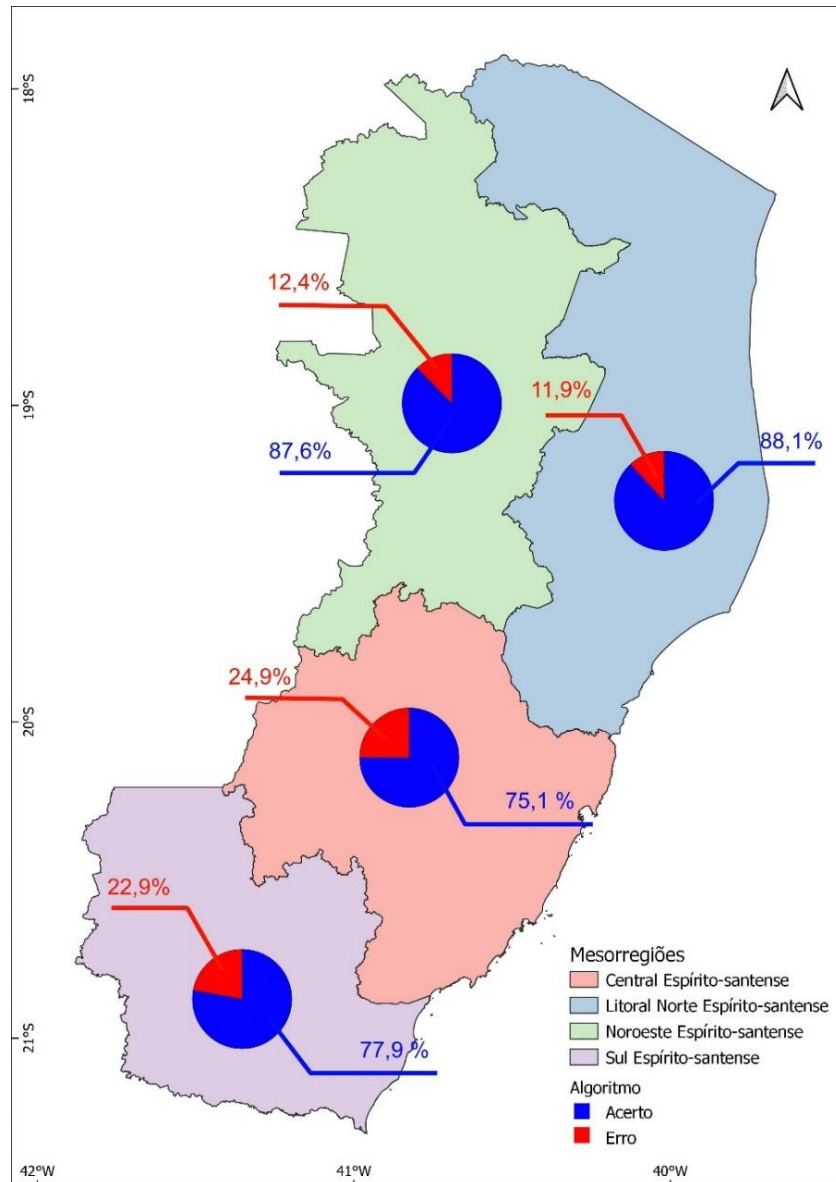
O primeiro aspecto é que as áreas de menor extensão, compreendidas nos intervalos de 0 a 5 hectares, demonstram taxas de erro mais elevadas. À medida que as áreas se tornam mais extensas, a acurácia da classificação melhora consideravelmente. As categorias de 5 a 150 hectares exibem taxas de acerto

superiores a 85%, com destaque para o intervalo de 20 a 30 hectares. Esses resultados indicam que a detecção de colheita de áreas de maior tamanho é mais precisa e menos suscetível a erros. A redução da acurácia ao observar povoamentos de *Eucalyptus* com menor área pode ser explicada pelo fato de que em talhões menores, há uma maior probabilidade de ocorrência de um pixel representar mais de uma classe no terreno (BITTENCOURT e HAERTEL, 2009). Isto tem um impacto significativo no processo de classificação do SCL, resultando em uma redução na acurácia da detecção de colheita.

Outro resultado relevante é quando se considera a acurácia do algoritmo em relação às diferentes mesorregiões do estado do Espírito Santo (Figura 17). Notavelmente, o estado apresenta variações significativas entre suas mesorregiões. As mesorregiões Litoral Norte e Noroeste do estado é caracterizado por uma topografia mais plana e pelo cultivo de talhões de eucalipto de maior extensão, devido à presença da fábrica da empresa Suzano, e concentra cerca de 72% dos talhões de eucalipto. Enquanto isso, as mesorregiões Sul e Central do estado são marcadas por um terreno mais acidentado e pela presença de inúmeros pequenos produtores, com plantios pulverizados, o que resulta em um tamanho médio dos talhões menor e uma quantidade menor de talhões (28%) (IBGE, 2009).

Essa distinção geográfica têm uma clara influência na acurácia do algoritmo de classificação. Como ilustrado na Figura 20, observa-se uma variação na acurácia da classificação entre as mesorregiões, trazendo uma diferença maior do que 10% na acurácia quando analisamos as mesorregiões Sul e Central em relação ao Litoral Norte e a região Noroeste. Isso é influência direta das características topográficas e da distribuição das áreas de cultivo em cada região, enfatizando a influência das características do local avaliado na performance do algoritmo.

Figura 20 – Mapa do desempenho do algoritmo por mesorregião



Fonte: Autor (2023)

6 CONCLUSÃO

A partir dos resultados apresentados neste trabalho, tem-se as seguintes conclusões:

- Na análise de nuvem, a composição que obteve o melhor resultado foi a trimestral;

- O algoritmo demonstrou alta acurácia ao avaliarmos a detecção de talhões com mais de 25% de pixels de solo. Portanto, ele pode ser aplicado com eficácia em estratégias de monitoramento de colheita no estado do Espírito Santo.

- Na detecção da colheita de povoamentos de *Eucalyptus*, quanto mais planos os talhões maiores a acurácia do algoritmo. Entretanto, mesmo em terrenos mais acidentados a acurácia ainda pode ser considerada alta para desempenho de algoritmos analisados.

- Os talhões de *Eucalyptus* com menores áreas tendem a apresentar menor acurácia, enquanto povoamentos com maiores áreas demonstram uma maior acurácia na detecção da colheita.

REFERÊNCIAS

- ADEU, R. de S. da S. **Clustering satellite image time series data based on growing self-organizing maps**. 2020. 49 f. Dissertação (Mestrado em Computação Aplicada), Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.
- AGÊNCIA ESPACIAL FRANCESA - CNES. **SPOT Satellite: Overview**. Disponível em: <https://earth.esa.int/web/guest/missions/3rd-party-missions/historic-missions/spot>. Acesso em: 28 mar. 2023.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ANDRADE, S. da C. **Avaliação técnica, social, econômica e ambiental de dois sistemas de colheita florestal no litoral Norte da Bahia**. Viçosa: UFV, 1998. 125p.
- ANDRADE, G. C. *et al.* **Cultivo de eucalipto em propriedades rurais: diversificação da produção e renda**. EMBRAPA. Brasília DF, 2014.
- AMARAL, M. V. F.; SOUZA, A. L.; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. C.; MARTINS, S. V.; FERNANDES FILHO, E. I.; LANA, J. M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, Viçosa-MG, v.33, n.3, p.575-582, 2009.
- ALMEIDA, C. A. de *et al.* **Metodologia para monitoramento da floresta usada nos projetos PRODES e DETER**. Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos - SP – Brasi, v. 12, p. 010, 2021.
- ARTERO, A. O. **Inteligência artificial: teórica e prática**. 1. ed. São Paulo: Livraria da física, 2009. 230p.
- BITTENCOURT, Hélio R.; HAERTEL, Vitor. Detecção de mudanças a partir de imagens de fração: uma abordagem fuzzy empregando o conceito de pixel mistura. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009, Natal. **Anais...** São José dos Campos: INPE, 2009.
- BLASCHKE, T. A. **framework for change detection based on image objects**. In: ERASMI, S., CYFFKA, B.; KAPPAS, M. (Eds.) *Göttinger Geographische Abhandlungen*, v.113, p. 1-9. 2005.
- BLASCHKE, T.; KUX, H. **Sensoriamento remoto e SIG avançados: novos sistemas sensores, métodos inovadores**. Oficina de Textos, 2005, São Paulo, p. 1-304.
- BOVOLO, F. *et al.* A hyper-spherical SVM approach for change detection in VHR multispectral images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 50, n. 11, p. 4355-4367, 2012.

BOVOLO, F. A multilevel parcel-based approach to change detection in very high resolution multitemporal images. **Institute of Electrical and Electronics Engineers Geoscience and Remote Sensing Letters**, v. 6, n. 1, p. 33-37, 2009.

BOVOLO, F.; BRUZZONE, L. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain. **Institute of Electrical and Electronics Engineers Transactions Geoscience and Remote Sensing**, v. 45, n. 1, p. 218-236, 2007.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2012. 226p.

BRAMUCCI, M. **Determinação e quantificação de fatores de influência sobre a produtividade de “Harvesters” na colheita da madeira**. 2001. 50 p. Dissertação (Mestrado em Recursos Florestais), Universidade de São Paulo, Piracicaba, 2001.

BRUZZONE, L.; COSSU, R., An adaptive approach for reducing registration noise effects in unsupervised change detection. **Institute of Electrical and Electronics Engineers Transactions Geoscience and Remote Sensing**, v. 41, n. 11, p. 2455-2465, 2003.

CARNUS, J.-M. *et al.* Planted forests and biodiversity. **Journal of forestry**, v. 104, n. 2, p. 65-77, 2006.

CEDAGRO. **Dimensionamento do setor de base florestal no estado do Espírito Santo. Vitória – ES 2022**. Disponível em: <http://www.cedagro.org.br/arquivos/ESTUDO%20MERCADO%20DE%20MADEIRA_%20FINAL%20PDF.pdf>. Acesso em: 13/12/2022.

CHUVIECO, E. **Remote sensing of vegetation: principles, techniques, and applications**. Boca Raton, 432 p. Springer, 2019.

CREPANI, E.; MEDEIROS, J. S.; Filho, P. H.; Florenzano, T. G.; Duarte, V.; Barbosa, C. C. F. **Sensoriamento remoto e geoprocessamento aplicados ao zoneamento ecológicoeconômico e ao ordenamento territorial**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. 101 p.

CREPANI, E.; MEDEIROS, J. S. **Imagens fotográficas derivadas de MNT do Projeto SRTM para fotointerpretação na geologia, geomorfologia e pedologia**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2004. 39 p.

CROSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: UNICAMP, 1992. 170 p.

DALLA MURA, M.; BENEDIKTSSON; J.A.; BOVOLO; F., BRUZZONE, L. An unsupervised technique based on morphological filters for change detection in very high-resolution images. **Institute of Electrical and Electronics Engineers Transactions Geoscience and Remote Sensing**, v. 5, n. 3, p. 433-437, 2008.

DAO, P. D.; LIOU, Yu'ei-An. Object-based flood mapping and affected rice field estimation with Landsat 8 OLI and MODIS data. **Remote Sensing**, v. 7, n. 5, p. 5077-5097, 2015.

MORAES NOVO, E. M.L. **Sensoriamento Remoto: princípios e aplicações**. Editora Blucher, 2010, São Paulo, p.1-383.

EMBRAPA INFORMÁTICA AGROPECUÁRIA. **Sistema de análise temporal da vegetação-SATVeg**. Campinas, 2014. Disponível em: <<https://www.satveg.cnptia.embrapa.br/satveg/login.html>>. Acesso em 12 de julho de 2022.

ESPÍRITO SANTO. **Instrução Normativa nº 01, 09 de janeiro de 2020**. Disponível em: <<https://idaf.es.gov.br/Media/idaf/Documentos/Legislação/DRNRE/IN%20IDAF%20001-20%20-%20Informação%20de%20Corte%20alterada.pdf>> Acesso em: 06 julho. 2023.

ESA, (2015). **Sentinel-2 User Handbook. 1–64**. Acesso em: <https://earth.esa.int/documents/247904/685211/Sentinel-2_User_Handbook>. Acesso em: 10/12/2022

Espirito Santo, constituição (1996), Inciso XX, Art 39, **Lei Estadual nº 5.361/1996**. Disponível em: <<https://idaf.es.gov.br/Media/idaf/Documentos/Legislação/DRNRE/Lei%20estadual%2005.361-96%20-%20Política%20florestal%20do%20Estado.pdf>>, acesso em: 26/09/2023

FAO. 2020. **Global forest resources assessment 2020: main report**. Rome. Acesso em 28/12/2022: <https://doi.org/10.4060/ca9825en>.

FELGUEIRAS, C.A.; Erthal, G.J. **Aplicações de modelos numéricos de elevação e integração com imagens digitais**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 1988.

FERREIRA, M. V. *et al.* Comparação entre técnicas de classificação digital de imagens para detecção de mudanças do uso e cobertura da terra. **Revista Brasileira de Cartografia**, v. 62, n. 04, 15 p 2010.

FOELKEL, C. **Gestão Ecoeficiente Dos Resíduos Florestais Lenhosos Da Eucaliptocultura**, Eucalyptus Online Book & Newsletter, 2007.

FONSECA, L. M. G. **Processamento digital de imagens**. Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. [S.I.]: Oficina de Textos, 2017.

FREITAS, L. C.; MACHADO, C.C.; SANT'ANNA, G. L.; SOUSA, H. T. Ferramentas computacionais no planejamento da colheita florestal, **Revista da Madeira, nº 92**, out., 2005.

HANSEN, M.C. *et al.* High-resolution global maps of 21st-century forest cover Change. **Science**, v. 342, n. 6160, p. 850-853, 2013.

HASHEM, N.; BALAKRISHNAN, P. **Change analysis of land use/land cover and modelling urban growth in Greater Doha, Qatar**. *Annals of GIS*, v. 21, n. 3, p. 233-247, 2015.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900p.

HORNING, N. *et al.* **Remote sensing for ecology and conservation: a handbook of techniques**. p 496. Oxford University Press, 2010.

IBA. **Relatório Anual 2023**. São Paulo–SP: Indústria Brasileira de Árvores. (2023), p 87.

IBGE. **Censo 2010**. Disponível em :<https://cidades.ibge.gov.br/>. Acesso em: 10/12/2022.

IDAF (Instituto de Defesa Agropecuária e Florestal). **Instrução Normativa nº 002**, de 15 de março de 2021. Disponível em: <<https://idaf.es.gov.br/Media/idaf/Documentos/Legislação/DRNRE/IN%20IDAF%2001-20%20-%20Informação%20de%20Corte%20alterada.pdf>>. Acesso em: 12/12/2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (Brasil). Manual Técnico de Geomorfologia. Segunda edição. Rio de Janeiro: IBGE, 2009. 182p. (**Manuais técnicos em geociências**, ISSN 0103-9598; n. 5)

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Programa CBERS**. Disponível em: <http://www.cbbers.inpe.br/>. Acesso em: 28 mar. 2023.

JONES, H. G.; VAUGHAN, Robin A. **Remote sensing of vegetation: principles, techniques, and applications**. Oxford university press, 2010.

KURKDJIAN, M.L.N.O. *et al.* **Macrozoneamento da região do Vale do Paraíba e Litoral Norte do Estado de São Paulo**. São José dos Campos, INPE, 1992.176p. (INPE 5381-PRP/165).

MACHADO, C.C. **Colheita Florestal**. Viçosa-MG: UFV, 2002. 468 p.

MACHADO, C. C. **Colheita Florestal**. Viçosa-MG, UFV, 2008. 501 p.

MALILA, W. A. Change vector analysis: An approach for detecting forest changes with Landsat, In: LARS Symposia, 1980, West Lafayette, Indiana, USA. Proceedings. West Lafayette: **IEEE Transactions Geoscience and Remote**, 1980. p. 326–336.

MAPBIOMAS. **MapBiomas General “Handbook” Algorithm Theoretical Basis Document (ATBD) Collection 7**. São Paulo: MapBiomas, 2020. Disponível em: <https://mapbiomas.org/>. Acesso em: 07 mar. 2023.

MATSUSHITA, B, *et al.* **Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest.** *Sensors*. v. 7, n. 11, p. 2636-2651, 2007.

MENDONÇA FILHO, W.F. Abate de árvores totalmente mecanizado. In: Simpósio brasileiro sobre exploração, transporte, ergonomia e segurança em reflorestamento, 1., 1987, Curitiba. **Anais...** Curitiba, UFPr/FUPEF, 1987. p.267-80.

MOHAJERANI, S.; KRAMMER, T. A.; SAEEDI, Parvaneh. Cloud Detection Algorithm for Remote Sensing Images Using Fully Convolutional Neural Networks. **2018 Institute of Electrical and Electronics Engineers 20th International Workshop on Multimedia Signal Processing, MMSP 2018**. Disponível em: <https://doi.org/10.1109/MMSP.2018.8547095>. Acesso em: 3 jan. 2022.

MORAES, E. C. **Fundamentos do sensoriamento remoto**. In: RUDORFF, B. F. T. *et al.* Curso de uso de sensoriamento remoto no estudo do meio ambiente. São José dos Campos: INPE, 2002. Cap 1, p. 1-22.

PEREIRA, J. C. D., *et al.* **Características da madeira de algumas espécies de eucalipto plantadas no Brasil**. 2000.

R CORE TEAM. **R: A Language and Environment for Statistical Computing. Vienna, Austria: R Foundation for Statistical Computing, 2021**. Disponível em: <https://www.R-project.org/>. Acesso em: 06 outubro 2023.

RAIYANI, K. *et al.* Sentinel-2 image scene classification: A comparison between Sen2Cor and a machine learning approach. **Remote Sensing**, v. 13, n. 2, p. 300, 2021.

REICHE, J. *et al.* Forest disturbance alerts for the Congo Basin using Sentinel-1. **Environmental Research Letters**, v. 16, n. 2, p. 024005, 2021.

REICHE J, de Bruin S, Hoekman D H, Verbesselt J and Herold M 2015. A Bayesian approach to combine Landsat and ALOS PALSAR time series for near real-time deforestation detection. **Remote Sensing**. 7 4973–96

REICHE, J. *et al.* Forest disturbance alerts for the Congo Basin using Sentinel-1. **Environmental Research Letters**, v. 16, n. 2, p. 024005, 2021.

SCHUMACHER, M. V.; VIEIRA, M. (Ed.). **Silvicultura do Eucalipto no Brasil**. Santa Maria: Fundação de Apoio a Tecnologia e Ciência-Editora UFSM, 2016. p. 273-307.

SIMONETTI, D. *et al.* Pan-tropical Sentinel-2 cloud-free annual composite datasets. **Data in Brief**, v. 39, p. 107488, 2021.

SINGH, A. Digital Change Detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989–1003, 1989.

SOUZA, C.; AZEVEDO, Tasso. **MapBiomass general handbook**. MapBiomass: São Paulo, Brazil, p. 1-23, 2017.

SANTOS, L. S. dos. Mecanização florestal no Brasil. **Revista Madeira**, Curitiba, n. 51. p. 43- 44, ago., 2000.

TORRES, R. *et al.* GMES Sentinel-1 mission. **Remote sensing of environment**, v. 120, p. 9-24, 2012.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat Program**. Disponível em: <<https://www.usgs.gov/core-science-systems/nli/landsat>>. Acesso em: 28 mar. 2023.

VENTURIERI, A., SANTOS, J.R.dos. **Técnicas de classificação de imagens para análise de cobertura vegetal**. Em: ASSAD, E.D., SANO, E.E. Sistema de informações geográficas aplicações na agricultura. 2 ed. Brasília: Embrapa, 1998. p. 351 - 371.

VITAL, M. H. F. Impacto ambiental de florestas de eucalipto. **Revista do BNDES**, v. 14, n. 28, p. 235-276, 2007. Disponível em:<<https://web.bndes.gov.br/bib/jspui/handle/1408/12554> > . Acesso em: 10 julho 2023.

XIAOLONG, D; KHORRAM, S. The effects of image misregistration on the accuracy of remotely sensed change detection, **Institute of Electrical and Electronics Engineers Transactions Geoscience and Remote**, v. 36, n. 5, p. 1566-1577, 1998.