



UnB

UNIVERSIDADE DE BRASÍLIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DO USO DE SATÉLITES ÓPTICOS NO MAPEAMENTO
DE CLAREIRAS SOB MANEJO FLORESTAL, A PARTIR DE
TÉCNICAS DE CLASSIFICAÇÃO EM INTELIGÊNCIA
ARTIFICIAL (MACHINE LEARNING) NA FLORESTA
NACIONAL DE ALTAMIRA**

Fabício Alves Rodrigues

Dissertação de Mestrado

Brasília-DF, 29 de fevereiro de 2024



UnB

UNIVERSIDADE DE BRASÍLIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DO USO DE SATÉLITES ÓPTICOS NO MAPEAMENTO
DE CLAREIRAS SOB MANEJO FLORESTAL, A PARTIR DE
TÉCNICAS DE CLASSIFICAÇÃO EM INTELIGÊNCIA
ARTIFICIAL (MACHINE LEARNING) NA FLORESTA
NACIONAL DE ALTAMIRA**

Fabício Alves Rodrigues

Orientador: Roberto Arnaldo Trancoso Gomes

Dissertação de Mestrado

Brasília-DF, 29 de fevereiro de 2024

UNIVERSIDADE DE BRASÍLIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DO USO DE SATÉLITES ÓPTICOS NO MAPEAMENTO DE CLAREIRAS
SOB MANEJO FLORESTAL, A PARTIR DE TÉCNICAS DE CLASSIFICAÇÃO EM
INTELIGÊNCIA ARTIFICIAL (MACHINE LEARNING) NA FLORESTA
NACIONAL DE ALTAMIRA**

Fabício Alves Rodrigues

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, área de concentração gestão ambiental e territorial, linha de pesquisa geoprocessamento.

Aprovado por:

Professor Dr. Roberto Arnaldo Trancoso Gomes (Presidente - Orientador) – PPGGEA-UnB

Analista Ambiental Dr^a. Nara Vidal Pantoja (Ibama) – Examinadora externa.

Professora Dr^a. Potira Meirelles Hermuche - Examinadora interna – PPGGEA-UnB

Brasília-DF, 29 de fevereiro de 2024

Ficha catalográfica.

RODRIGUES, FABRÍCIO ALVES

Análise do uso de satélites ópticos no mapeamento de clareiras sob manejo florestal, a partir de técnicas de classificação em inteligência artificial (machine learning) na Floresta Nacional de Altamira 108 p., (UnB-IH-GEA, Mestre, Gestão Ambiental e Territorial, 2024).

Dissertação de Mestrado – Universidade de Brasília. Instituto de Ciências Humanas – Departamento de Geografia.

1. Floresta Amazônica

2. Concessões Florestais

3. Sentinel-2 MSI

4. Cbers 4A WPM

5. PlanetScope

I. UnB-GEA .

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

Fabrício Alves Rodrigues

AGRADECIMENTOS

Ao Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (Ibama) por autorizar, no contexto do programa governamental Brasil Mais, a utilização das imagens PlanetScope¹.

Ao Serviço Florestal Brasileiro (SFB) por disponibilizar os dados Light Detection and Ranging (Lidar) utilizados na pesquisa.

Aos sertanejos nordestinos, verdadeiros construtores desta universidade e desta capital, dedico este trabalho com especial gratidão ao meu pai, José Alves de Oliveira, que, com suas poucas horas de estudo, possibilitou a realização desta dissertação de mestrado.

¹ Rede MAIS/MJSP, inclui material © (2023) Planet Labs Inc. Todos os direitos reservados.

RESUMO

A Conferência Rio+20 destacou os benefícios sociais, econômicos e ambientais do Manejo Florestal Sustentável (MFS) como parte dos esforços em direção ao desenvolvimento sustentável (ONU, 2012). Uma análise realizada por Putz et al. (2012) revela que florestas bem manejadas retêm reservas substanciais de biodiversidade, carbono e madeira e devem ser avaliadas como um caminho intermediário entre o desmatamento e a proteção integral. No entanto, é crucial que haja capacidade de monitoramento para garantir sua adequada implementação. As clareiras florestais são consideradas bons indicadores para a avaliação do impacto da atividade madeireira, pois estão relacionadas a processos ecológicos essenciais, todavia, não é fácil mapeá-las. As florestas sob MFS apresentam um mosaico complexo de ambientes, tornando desafiador o monitoramento dessas mudanças por meio de sensores orbitais. Esta pesquisa tem como objetivo, por meio da classificação supervisionada de imagens Cbers 4A WPM, PlanetScope e Sentinel-2 MSI, avaliar a capacidade desses sensores em mapear clareiras florestais, logo após o término da atividade madeireira, em área sob concessão na Floresta Nacional de Altamira. Foram empregadas diversas combinações de bandas espectrais e processamentos, incluindo o cálculo do NDVI, fusão espectral, reamostragem de resolução espacial e técnicas de mapeamento Pixel a Pixel e Análise Baseada em Objetos Geográficos (Geobia), resultando em 14 conjuntos de dados distintos. Cada um foi classificado por meio dos algoritmos baseados em aprendizagem de máquina: K-Nearest Neighbors (K-NN), Random Forest (RF) e Support Vector Machine (SVM), totalizando 42 mapeamentos. Foram realizadas três formas diferentes de validação dos resultados: (1) validação baseada no método Out-of-bag (OOB); (2) taxa de detecção da infraestrutura instalada; e (3) validação baseada em mapeamentos realizados com dados Lidar aerotransportado. As médias dos resultados de F-score pelo método OOB foram de 99% para o sensor Cbers 4A WPM, 96,71% para o sensor PlanetScope e de 97,86% para Sentinel-2 MSI. A taxa média de detecção dos pátios de estocagem superou os 99%, alcançando, em média, 60,95% para as estradas principais e 36,97% para as secundárias. A área total de clareiras mapeadas com os sensores ópticos abrangeu, em média, 9,52% da área total em estudo. No entanto, os quantitativos das clareiras mapeadas apresentaram diferenças significativas entre os sensores ópticos. Os resultados das métricas de validação com dados Lidar foram significativamente baixos, confirmando a complexidade em mapear essas feições. Os valores mais elevados obtidos para cada uma dessas métricas ficaram abaixo de 40% para Precisão e Recall e abaixo de 20% para F-score. Todavia, ao restringirmos a validação com dados Lidar às clareiras sobrepostas à infraestrutura instalada, os resultados foram, em média, 150% superiores.

Palavras-chave: Floresta Amazônica, Concessões Florestais, Sentinel-2 MSI, Cbers 4A WPM, PlanetScope.

ABSTRACT

The Rio+20 Conference highlighted the social, economic, and environmental benefits of Sustainable Forest Management (SFM) as part of the efforts towards sustainable development (UN, 2012). An analysis conducted by Putz et al. (2012) reveals that well-managed forests retain substantial reserves of biodiversity, carbon, and wood and should be considered an intermediate path between deforestation and full protection. However, it is crucial to have monitoring capacity to ensure its proper implementation. Canopy openings are considered good indicators for assessing the impact of logging activities as they are linked to essential ecological processes. Nevertheless, mapping them is not easy. Forests under SFM present a complex mosaic of environments, making it challenging to monitor these changes through orbital sensors. This research aims, through supervised classification of Cbers 4A WPM, PlanetScope, and Sentinel-2 MSI images, to evaluate the capacity of these optical sensors to map canopy openings, shortly after the completion of logging activities, in concession areas within Altamira National Forest. Various combinations of spectral bands and processing techniques were employed, including NDVI calculation, spectral fusion, spatial resolution resampling, Pixel-to-Pixel mapping, and Geographic Object-Based Image Analysis, resulting in 14 distinct datasets. Each was classified using machine learning-based algorithms: K-Nearest Neighbors (K-NN), Random Forest (RF), and Support Vector Machine (SVM), totaling 42 mappings. Three different validation methods were performed: (1) validation based on the Out-of-bag method (OOB); (2) detection rate of installed infrastructure; and (3) validation based on mappings using airborne Lidar data. The mean F-score results using the OOB method were 99% for the Cbers 4A WPM sensor, 96,71% for the PlanetScope sensor, and 97,86 for the Sentinel-2 MSI sensor. The average detection rate of storage yards exceeded 99%, reaching an average of 60.95% for main roads and 36.97% for secondary roads. The total area of Canopy openings mapped with optical sensors covered, on average, 9,52% of the total study area. However, the quantities of mapped showed significant differences between the optical sensors. The validation metrics results with Lidar data were significantly low, confirming the complexity in mapping these features. The highest values obtained for each of these metrics were below 40% for Precision and Recall and below 20% for F-score. Nevertheless, when limiting the Lidar validation to canopy openings overlapping installed infrastructure, the results were, on average, 150% higher.

Keywords: Amazon Forest, Forest Concessions, Sentinel-2 MSI, Cbers 4A WPM, PlanetScope.

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

1 INTRODUÇÃO	01
2 MANEJO FLORESTAL SUSTENTÁVEL E CONCESSÕES FLORESTAIS FEDERAIS	05
3 MAPEAMENTO DA SUPRESSÃO DE VEGETAÇÃO NA FLORESTA AMAZÔNICA	10
3.1 USO DE SENSORES ORBITAIS NO MAPEAMENTO FLORESTAL.....	10
3.2 MAPEAMENTO DA EXPLORAÇÃO SELETIVA DE MADEIRA COM SENSOR LIDAR.....	16
4 CLASSIFICAÇÃO DE IMAGENS	17
4.1 SEGMENTAÇÃO DE IMAGENS E ALGORITMO LARGE-SCALE MEAN-SHIFT (LSMS).....	19
4.2 CLASSIFICADORES BASEADOS EM APRENDIZAGEM DE MÁQUINA.....	21
4.2.1 Random Forest	22
4.2.2 K-Nearest Neighbors	23
4.2.3 Support Vector Machine	24
5 ÁREA DE ESTUDO	26
6 MATERIAIS E MÉTODOS	29
6.1 PARAMETRIZAÇÃO DO ALGORITMO DE SEGMENTAÇÃO.....	37
6.2 SELEÇÃO DAS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO INTERNA.....	40
6.3 PARAMETRIZAÇÃO DOS ALGORITMOS DE CLASSIFICAÇÃO.....	45
6.4 VALIDAÇÃO ATRAVÉS DA LOCALIZAÇÃO DA INFRAESTRUTURA INSTALADA E DOS DADOS LIDAR.....	48
6.5 MÉTRICAS DE CONCORDÂNCIA UTILIZADAS PARA VALIDAÇÃO.....	53
7 RESULTADOS	55

7.1 QUANTIFICAÇÃO DAS CLAREIRAS FLORESTAIS MAPEADAS COM SENSORES ÓPTICOS E VALIDAÇÃO PELO MÉTODO OOB.....	55
7.2 VALIDAÇÃO ATRAVÉS DA LOCALIZAÇÃO DA INFRAESTRUTURA.....	60
7.3 VALIDAÇÃO COM O USO DE DADOS LIDAR AEROTRANSPORTADOS.....	63
8 DISCUSSÃO.....	75
9 CONCLUSÕES.....	78
REFERÊNCIAS BIBLIOGRÁFICAS.....	82
ANEXOS.....	102

LISTA DE FIGURAS

FIGURA 01. Algoritmo Random Forest.....	22
FIGURA 02. Algoritmo K-NN.....	24
FIGURA 03. Algoritmo SVM.....	24
FIGURA 04. Transformações de Kernel.....	25
FIGURA 05. Área de Trabalho e Área de Controle (sobrevoo com Lidar).....	27
FIGURA 06. Nuvem de pontos em uma das faixas de mapeamento com Lidar.....	33
FIGURA 07. Formação dos conjuntos de dados com imagens Cbers 4A WPM.....	xx
FIGURA 08. Formação dos conjuntos dados com imagens PlanetScope.....	xx
FIGURA 09. Formação dos conjuntos dados com imagens Sentinel-2 MSI.....	xx
FIGURA 10 Segmentação de imagem Cbers 4A WPM fusionada.....	39
FIGURA 11. Segmentação de imagem PlanetScope.....	39
FIGURA 12. Segmentação de imagem Cbers 4A WPM fusionada.....	39
FIGURA 13. Segmentação de imagem PlanetScope.....	39
FIGURA 14. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Cbers 4A WPM com oito metros de resolução espacial.....	42
FIGURA 15. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Cbers 4A WPM com dois metros de resolução espacial.....	42
FIGURA 16. Exemplo de amostras coletadas para classificação por Geobia em imagem Cbers 4A WPM com dois metros de resolução espacial.....	42
FIGURA 17. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem PlanetScope.....	42
FIGURA 18. Exemplo de amostras coletadas para classificação por Geobia em imagem PlanetScope.....	43
FIGURA 19. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Sentinel-2 MSI.....	43
FIGURA 20. Exemplo de assinatura espectral média de amostras coletadas com dados Cbers 4A WPM em resolução espacial de oito metros.....	43
FIGURA 21. Exemplo de assinatura espectral média de amostras coletadas com dados Cbers 4A WPM em resolução espacial de dois metros.....	44
FIGURA 22. Exemplo de assinatura espectral média de amostras coletadas com dados PlanetScope.....	44

FIGURA 23. Exemplo de assinatura espectral média de amostras coletadas com dados Sentinel-2 MSI com quatro bandas espectrais.....	44
FIGURA 24. Exemplo de assinatura espectral média de amostras coletadas com dados Sentinel-2 MSI com dez bandas espectrais.....	45
FIGURA 25. Modelo de Altura de Dossel (MAD).....	49
FIGURA 26. Modelo Digital de Superfície (MDS) da Área de Controle.....	50
FIGURA 27. Modelo Digital de Terreno (MDT) da Área de Controle.....	50
FIGURA 28. Modelo de Altura de Dossel (MAD) da Área de Controle.....	50
FIGURA 29. Fluxo de trabalho do mapeamento das clareiras com dados Lidar.....	52
FIGURA 30. Exemplo de clareiras com no mínimo 20m ² mapeadas com dados Lidar.....	52
FIGURA 31. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) agrupadas por tipo de sensor óptico utilizado.....	56
FIGURA 32. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe clareira, agrupadas por tipo de sensor óptico, resolução espacial, bandas espectrais e técnica de mapeamento empregadas.....	57
FIGURA 33. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe clareira agrupados por tipo de algoritmo utilizado.....	58
FIGURA 34. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe Clareira agrupados por algoritmo, e sensor óptico utilizado.....	58
FIGURA 35. Percentual médio da infraestrutura detectada e valor percentual médio das clareiras mapeadas em relação à área da UPA 4D em cada conjunto de dados classificados com sensores ópticos.....	61
FIGURA 36. Percentual médio da infraestrutura detectada nas classificações realizadas com sensores ópticos, agrupado por sensor, resolução espacial e técnica de mapeamento empregada.....	61
FIGURA 37. Clareiras Lidar \geq 20m ²	64
FIGURA 38. Clareiras Lidar \geq 40m ²	64
FIGURA 39. Clareiras Lidar \geq 40m ² sobrepostas à infraestrutura.	64
FIGURA 40. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC, agrupados por tipo de sensor.....	67
FIGURA 41. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC, agrupados por tipo de sensor, resolução espacial, bandas espectrais / NDVI e técnicas de mapeamento utilizadas.....	69

FIGURA 42. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC agrupados por tipo de algoritmo utilizado.....	70
FIGURA 43. Valores percentuais dos desvios padrão dos resultados das métricas de concordância em função do tipo de algoritmo utilizado em cada conjunto de dados classificado.....	70
FIGURA 44. Valores médios das métricas de concordância nos mapeamentos das clareiras sobrepostas à infraestrutura. Dados agrupados por tipo de sensor, resolução espacial, bandas / NDVI e técnica de mapeamento adotada.....	72
FIGURA 45. Valor médio do ganho em Precisão ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.....	73
FIGURA 46. Valor médio do ganho em relação à métrica Recall ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.....	73
FIGURA 47. Valor médio do ganho em relação à métrica F-score ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.....	73
FIGURA 48. Percentual médio das áreas de clareiras mapeadas por unidade de área explorada agrupadas por tipo de sensor óptico em comparação a outros estudos em áreas sob MFS.....	xx

LISTA DE TABELAS

TABELA 01. Características gerais dos sensores ópticos.....	29
TABELA 02. Bandas espectrais - PlanetScope.....	30
TABELA 03. Bandas espectrais utilizadas - Sentinel-2 MSI.....	31
TABELA 04. Bandas espectrais - Cbers 4A WPM.....	32
TABELA 05. Conjuntos dados com os sensores ópticos classificados.....	36
TABELA 06. Parametrização adotada e estatísticas dos resultados da segmentação.....	38
TABELA 07. Quantitativo de amostras utilizadas para classificação e validação de cada conjunto de dados com o uso da técnica pixel a pixel.....	41
TABELA 08. Quantitativo de amostras utilizadas para classificação e validação de cada conjunto de dados com o uso da técnica Geobia.....	42
TABELA 09. Configuração do principal parâmetro dos algoritmos de classificação em cada conjunto de dados.....	46
TABELA 10. Percentual de clareiras mapeadas em relação à área da UPA 4D e resultados da métrica F-score (OOB) da classe clareira em cada conjunto de dados classificados com sensores ópticos.....	55

TABELA 11. Percentual médio da área ocupada pelas clareiras mapeadas com cada conjunto de dados em relação a UPA 4D e a AC.....	59
TABELA 12. Percentual médio da infraestrutura detectada nas classificações realizadas com sensores ópticos em cada conjunto de dados classificados com sensores ópticos.....	60
TABELA 13. Valores médios das métricas de concordância agrupados para os 14 conjuntos de dados classificados com sensores ópticos.....	66
TABELA 14. Valores médios dos resultados das métricas de concordância nos mapeamentos de todas as clareiras, em comparação aos resultados dos mapeamentos das clareiras sobrepostas à infraestrutura instalada.....	71

LISTA DE ABREVIATURAS E SIGLAS

AC – Área de Controle

ADABOOST - Adaptive Boosting

BNDES - Banco Nacional de Desenvolvimento Econômico e Social

CBERS - Satélite Sino-Brasileiro de Recursos Terrestres

DT – Decision Tree

DETER - Sistema de Detecção de Desmatamento em Tempo Real

DETEX - Sistema de Detecção da Exploração Seletiva

EIR - Exploração de Impacto Reduzido

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária

ESM – Exploração Seletiva de Madeira

ESA - Agência Espacial Europeia

FAO - Organização das Nações Unidas para Agricultura e Alimentação

FLONA - Floresta Nacional

FNDF - Fundo Nacional de Desenvolvimento Florestal

FUNAI - Fundação Nacional dos Povos Indígenas

GEOBIA – Análise de Imagem Baseada em Objetos Geográficos

IBAMA - Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis

IBGE – Instituto Brasileiro de Geografia e Estatística

ICMBIO - Instituto Chico Mendes de Biodiversidade e Florestas

INPE - Instituto Nacional de Pesquisas Espaciais

IPCC - Painel Intergovernamental sobre Mudanças Climáticas

ITTO - Organização Internacional de Madeira Tropical

K-NN - K-Nearest Neighbors

LGFP - Lei de Gestão de Florestas Públicas

LIDAR - Light Detection and Ranging

LSM - Lidar Digital Surface Model

MFS - Manejo Florestal Sustentável

MLC - Maximum-Likelihood Classifier

MMA - Ministério do Meio Ambiente

MME – Modelo de Mistura Espectral

MSI - MultiSpectral Instrument

NDVI - Índice de Vegetação da Diferença Normalizada

OOB – Out-of-bag

PMFS - Plano de Manejo Florestal Sustentável

POA - Plano Operacional Anual

PPAOF - Plano Plurianual de Outorga Florestal

PPCDAM - Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal

PRODES - Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite

REDD - Redução de Emissões Provenientes de Desmatamento e Degradação Florestal

RF - Random Forest

SFB - Serviço Florestal Brasileiro

SINAFLOR - Sistema Nacional de Controle da Origem dos Produtos Florestais

SVM - Support Vector Machine

UC - Unidade de Conservação

UMF - Unidade de Manejo Florestal

UPA - Unidade de Produção Anual

WPM - Wide-Scan Panchromatic and Multispectral

WTB - Whitebox Tools

1. INTRODUÇÃO

A Floresta Amazônica presta inestimáveis serviços ambientais ao abrigar uma das maiores biodiversidades do planeta, incluindo muitas espécies raras ou ainda não identificadas pela ciência (SHUBART, 1983; GROOMBRIDGE & JENKINS, 2003; DA SILVA et al., 2005; STEEGE et al., 2013; PIMM et al., 2014). Como a maior floresta tropical do mundo, ela atua como um importante regulador do clima devido à sua notável capacidade de absorver e armazenar carbono (MALHI et al., 2006; BONAN, 2008). Além disso, desempenha um papel vital na regulação do ciclo da água e geração de umidade para a atmosfera, influenciando os padrões de chuva em nível regional e continental (SALATI, 1983; VAN DER ENT et al., 2010).

A Floresta Amazônica também é uma fonte crucial de recursos naturais, fornecendo alimentos, madeira, medicamentos e desempenhando um papel essencial na cultura e subsistência de comunidades locais. Todavia, as alterações climáticas e o avanço do desmatamento e da degradação florestal está colocando em xeque a capacidade da floresta em prestar seus relevantes serviços (FODEN et al., 2013; GATTI et al., 2014; BRIENEN et al., 2015; MITCHARD, 2018).

Entre os anos de 2009 e 2021, mais de 91.000 km² (área maior que a da Guiana Francesa) da Floresta Amazônica no Brasil foram desmatados, principalmente para a formação de pastagens (INPE, 2022a; MAPBIOMAS, 2022). Devido à sua maior extensão em relação ao desmatamento, estima-se que a degradação florestal, embora não envolva a remoção completa da vegetação, seja responsável por 73% das emissões de carbono na Amazônia brasileira, (INPE, 2017; QIN et al., 2021). Além disso, preocupa o avanço da exploração de recursos naturais para áreas centrais e preservadas da floresta Amazônica (SCHIELEIN et al., 2018; VALDIONES et al., 2022).

O controle e a aplicação da lei na Amazônia representam desafios extremamente complexos, resultantes de uma combinação de fatores históricos, geográficos, econômicos, sociais, político-institucionais e tecnológicos (BECKER, 1982; OLIVEIRA, 1991; FEARNSSIDE, 2008; SCHMITT, 2015; MOUTINHO et al., 2016; CARVALHO et al., 2019). Estimativas apontam que, em 2013, aproximadamente um quarto do volume global de madeira ilegal transacionada tinha origem no Brasil (HOARE, 2015). Nesse contexto, relatório das Nações Unidas adverte que a demanda por madeira é tão significativa que a extração ilegal continuará sendo uma preocupação para o futuro dos recursos florestais, a menos que esforços eficazes sejam empreendidos para contê-la (FAO & UNEP, 2020, p. 93).

Observa-se em nível global que regiões com maior cobertura florestal tendem a ter maiores taxas de pobreza (FAO & UNEP, 2020). No entanto, uma correlação direta entre desmatamento e progresso social na Amazônia não é estabelecida. Pelo contrário, como apontado por Santos et al. (2021), os municípios com maior perda florestal apresentam índices de desenvolvimento abaixo da média regional. Portanto, as políticas públicas para a região devem buscar, sempre que possível, um equilíbrio entre a conservação dos recursos ambientais e o fomento de projetos que estimulem a criação e manutenção de empregos formais às comunidades locais e a geração de receitas aos estados e municípios.

A Conferência das Nações Unidas sobre Desenvolvimento Sustentável conhecida como Rio+20, ressaltou a necessidade de se promover um crescimento econômico que seja sustentável e inclusivo, que proporcione maiores oportunidades para todos, por meio da redução de desigualdades, e elevação dos padrões de vida básicos, ao mesmo tempo em que facilitam a conservação e a regeneração dos ecossistemas. Nesse contexto, a conferência destaca os benefícios sociais, econômicos e ambientais das políticas que promovam o Manejo Florestal Sustentável (MFS) e o comércio de produtos florestais extraídos legalmente como parte dos esforços em direção ao desenvolvimento sustentável (ONU, 2012). Em consonância, o Plano Estratégico da ONU para Florestas 2017–2030 estabelece como um de seus objetivos centrais a expansão de áreas de florestas protegidas e geridas sustentavelmente, promovendo, desse modo, uma melhor governança e o aumento da proporção de produtos florestais sustentáveis em nível global (ONU, 2017).

Documento produzido por pesquisadores reunidos, sob a organização da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) aponta que: “embora as práticas de manejo causem distúrbios ou perturbações, em nível local, em escala ampla de tempo e espaço não devem ser consideradas uma fonte de degradação florestal em si” (FERREIRA et al., 2015, p.20). Todavia, caso o MFS não siga aos critérios estabelecidos em atos normativos e em boas práticas de sustentabilidade, baseadas no conhecimento da floresta e nas técnicas de Exploração de Impacto Reduzido (EIR), poderá levar à degradação da terra (IPCC, 2019).

Para garantir uma implementação adequada do MFS, é crucial que haja capacidade estatal de monitoramento (FAO, 2020). Para Bustamante et al. (2016), sistemas de monitoramento das dinâmicas florestais representam uma importante conexão entre a ciência e a execução de políticas públicas.

No entanto, a detecção da degradação florestal continua sendo um desafio significativo, uma vez que está condicionada ao tipo, frequência, intensidade, extensão e às

características intrínsecas específicas da área em estudo. Conforme destacado por Mitchard (2018), a falta de dados de referência confiáveis sobre as taxas de degradação florestal em nível global torna ainda mais complexa a implementação de mecanismos financeiros de apoio à redução desse processo, como é o caso do REDD (Redução de Emissões Provenientes de Desmatamento e Degradação Florestal).

É relevante salientar que o governo federal tem demonstrado um compromisso com a expansão acelerada da área de florestas públicas a serem concedidas à iniciativa privada para a realização de MFS (SFB, 2022b). Esse comprometimento sublinha a urgência de aprimorar e ampliar as ferramentas de monitoramento por sensoriamento remoto, especialmente considerando que essas áreas frequentemente se encontram em regiões de difícil acesso no interior da floresta amazônica.

Considerando que os sensores ópticos orbitais representam os meios mais acessíveis e amplamente utilizados para o monitoramento das dinâmicas florestais, é importante notar que, embora o olho humano seja exímio na distinção de cores e padrões em uma imagem, o cérebro não pode processar o volume de informações na velocidade com que os sistemas digitais de processamento de imagens são capazes (PARANHOS FILHO et al., 2020). Nesse contexto, a classificação de imagens constitui-se como uma alternativa técnica valiosa, visando extrair informações por meio do reconhecimento de padrões e objetos homogêneos em imagens (INPE, 2006a).

Adicionalmente, a utilização de algoritmos baseados em aprendizagem de máquina na classificação de imagens oferece benefícios substanciais, permitindo uma análise mais eficiente, precisa e adaptável em uma variedade de contextos (FRIEDL & BROADLEY, 1997; YU et al., 2014; LAWRENCE & MORAN, 2016; BELGIU & DRAGUT, 2016; KHATAMI et al., 2016; LI et al., 2016; MAXWELL et al., 2018; LOURENÇO et al., 2021).

No contexto das dinâmicas florestais, as aberturas no dossel florestal, também conhecidas como clareiras, são consideradas bons indicadores para a avaliação do impacto das atividades de MFS, pois estão diretamente relacionadas a processos ecológicos essenciais, como o balanço energético, o desenvolvimento da fauna, o microclima e a regeneração natural (SHUBART, 1983; ASNER et al., 2004; DE SOUSA et al., 2022). Conforme apontado por Asner et al. (2004), as clareiras são medidas relativamente simples e abrangentes da estrutura da floresta, sendo essenciais para compreender a dinâmica do dano no dossel das florestas tropicais exploradas. O mapeamento das clareiras florestais em áreas sob MFS desempenha um papel crucial para empreendedores, agências públicas de controle, certificadoras,

pesquisadores e para a sociedade em geral, fornecendo informações valiosas para avaliação dos impactos dessa atividade.

Sob a perspectiva da governança pública, o dimensionamento e a localização das clareiras são informações imprescindíveis para determinar se a infraestrutura instalada está em conformidade com as autorizações e se as áreas designadas para proteção e regeneração natural estão sendo respeitadas. O mapeamento das clareiras, combinado com a localização das árvores por meio de inventário florestal georreferenciado, e a exigência de que as empresas relatem cada árvore cortada nos sistemas públicos (IBAMA, 2014), possibilitam a detecção de possíveis indícios de irregularidades relacionadas à apresentação de informações falsas aos órgãos de controle.

Entretanto, a confiabilidade dessas verificações está intrinsecamente ligada à precisão dos mapeamentos das clareiras em áreas sob MFS. Nesse cenário, o objetivo geral desta pesquisa é realizar um extenso teste metodológico dos mapeamentos de clareiras em áreas sob MFS na Floresta Nacional (Flona) de Altamira, por meio da classificação supervisionada de imagens dos satélites Cbers 4A WPM, Sentinel-2 MSI e PlanetScope.

Com o intuito de avaliar o comportamento dos sensores sob diversas técnicas e composição de dados, foram empregadas variadas combinações de bandas espectrais e processamentos, incluindo o cálculo do NDVI, a fusão espectral, reamostragem de resolução espacial e as técnicas de mapeamento Pixel a Pixel e Análise Baseada em Objetos Geográficos (Geobia), resultando em 14 conjuntos de dados distintos. Cada conjunto foi classificado por meio dos algoritmos baseados em aprendizagem de máquina: K-Nearest Neighbors (K-NN), Random Forest (RF) e Support Vector Machine (SVM), totalizando 42 mapeamentos. Foram realizadas três formas diferentes de validação dos resultados: (1) validação baseada no método Out-of-bag (OOB); (2) taxa de detecção da infraestrutura instalada; e (3) validação baseada em mapeamentos realizados com dados Lidar aerotransportado. Neste contexto, são os objetivos específicos desta pesquisa:

1. Mensurar a área total de supressão do dossel florestal, considerando cada sensor, resolução espacial, conjunto de dados e técnica de processamento de imagens utilizada.
2. Quantificar a infraestrutura instalada, mapeada com cada sensor, resolução espacial, conjunto de dados e técnica de processamento de imagens utilizada.
3. Mapear as clareiras utilizando dados obtidos por sensor Lidar aerotransportado.

4. Analisar os mapeamentos das clareiras em relação a cada sensor, resolução espacial, conjunto de dados e técnica de processamento de imagens, utilizando como referência o mapeamento realizado com dados Lidar aerotransportado.

2. MANEJO FLORESTAL SUSTENTÁVEL E CONCESSÕES FLORESTAIS FEDERAIS

A Organização das Nações Unidas para Agricultura e Alimentação (FAO), aponta que a extensão de florestas sob MFS está em crescimento em todo o mundo, atingindo 2,05 bilhões de hectares em 2020. Entretanto, ao examinar os dados por continentes, nota-se que a maioria das florestas na Europa são manejadas, enquanto na África e na América do Sul, apenas 25% e 20% das florestas, respectivamente, contam com essa estratégia (FAO, 2020). O MFS é definido no contexto do Painel Intergovernamental sobre Mudança Climáticas (IPCC) como:

A gestão de florestas e áreas florestais de uma forma e a uma taxa que mantenha sua biodiversidade, produtividade, capacidade de regeneração, vitalidade e seu potencial para cumprir, agora e no futuro, funções ecológicas, econômicas e sociais relevantes, em nível local, nacional e global, e que não cause danos a outros ecossistemas (IPCC, 2019, p.351)

A Lei de Gestão de Florestas Públicas (LGFP) incorporou à legislação nacional a definição de MFS da seguinte forma:

A administração da floresta para a obtenção de benefícios econômicos, sociais e ambientais, respeitando-se os mecanismos de sustentação do ecossistema objeto do manejo e considerando-se, cumulativa ou alternativamente, a utilização de múltiplas espécies madeireiras, de múltiplos produtos e subprodutos não madeireiros, bem como a utilização de outros bens e serviços de natureza florestal (BRASIL, 2006a).

Ambas as definições, tanto a internacional quanto a nacional, partilham da mesma essência, o equilíbrio entre a conservação das florestas e a utilização responsável de seus recursos. Putz et al. (2012) revela que florestas bem manejadas retêm reservas substanciais de biodiversidade, carbono e madeira. Deste modo, devem ser avaliadas com atenção por pesquisadores, organizações civis, mercado e governos como um caminho intermediário entre o desmatamento e a proteção integral.

O IPCC aponta que a atividade de MFS reduz o risco de conversão da floresta para usos não-florestais, mantendo a produtividade econômica e reduzindo os riscos de degradação da terra (IPCC, 2019). Da mesma forma, pesquisa conduzida por organizações não governamentais examinou dados da cadeia produtiva do setor madeireiro na região amazônica brasileira nas últimas duas décadas, e concluiu que o MFS tem o potencial de estabelecer de

maneira sustentável a fronteira das atividades madeireiras na região, garantindo um fornecimento contínuo de matérias-primas (VALDIONES et al., 2022).

Segundo a Organização Internacional de Madeiras Tropicais (ITTO), a manutenção perpétua da cobertura florestal é considerada como uma condição essencial para o MFS. Nesse contexto, o estabelecimento de Florestas Estatais Permanentes (FEPs) deve ser encarado pelos governos como prioridade (ITTO, 2015). No Brasil, no âmbito da Administração Pública Federal, este conceito é melhor recepcionado por meio das Florestas Nacionais (Flonas), definidas pelo Sistema Nacional de Unidades de Conservação da seguinte maneira:

A Floresta Nacional é uma área com cobertura florestal de espécies predominantemente nativas e tem como objetivo básico o uso múltiplo sustentável dos recursos florestais e a pesquisa científica, com ênfase em métodos para exploração sustentável de florestas nativas (BRASIL, 2000).

O MFS nas Flonas é realizado por meio de concessões florestais, definidas pela LGFP da seguinte maneira:

Delegação onerosa, feita pelo poder concedente, do direito de praticar atividades de manejo florestal sustentável, de restauração florestal e de exploração de produtos e serviços em unidade de manejo, conforme especificado no objeto do contrato de concessão, mediante licitação, à pessoa jurídica, em consórcio ou não, que atenda às exigências do respectivo edital de licitação e demonstre capacidade para seu desempenho, por sua conta e risco e por prazo determinado (BRASIL, 2006a).

As concessões de florestas públicas representam um importante instrumento de gestão ambiental tendo como objetivo, a colaboração entre os setores público e privado, promovendo a conservação da vegetação nativa, mesmo quando sujeita à intervenção humana, por meio de práticas produtivas que visam minimizar os impactos ambientais.

Conforme destacado por Azevedo-Ramos et al. (2005), a presença de concessionários nas Flonas desempenhou um papel significativo na redução da vulnerabilidade dessas florestas à invasão e degradação florestal. Nesse contexto, o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm), adotado pelo governo brasileiro para o período de 2023 a 2027, estabelece a promoção do MFS como uma de seus objetivos estratégicos para prevenir e controlar o desmatamento e a degradação ambiental na região. (MMA, 2023).

Além das Flonas, as florestas públicas não destinadas² que estejam incluídas no Plano Plurianual de Outorga Florestal (PPAOF) também são elegíveis para concessão. Entretanto,

²Áreas arrecadadas pelo poder público, mas que ainda não têm destinação e uso específicos (BNDES, 2023).

atualmente, todas as concessões florestais federais na região amazônica estão localizadas em Flonas (SFB, 2022b). Cabe destacar que as florestas públicas não destinadas que compreendem, de acordo com o Banco Nacional de Desenvolvimento Econômico e Social (BNDES), aproximadamente 18% da área total das florestas públicas federais, representam um risco à conservação da floresta, visto que entre os anos de 2019 e 2021 essas áreas foram responsáveis por mais da metade do desmatamento na Amazônia Brasileira (ALENCAR et al., 2022; MOUTINHO et al., 2022; BNDES, 2023).

Em abril de 2022, o Serviço Florestal Brasileiro (SFB) registrou uma área total de 1,269 milhão de hectares de florestas públicas sob concessão florestal federal. Essas áreas estão distribuídas por 21 Unidades de Manejo Florestal (UMFs) e sete Flonas, localizadas nos estados de Rondônia, Pará e Amapá. No entanto, o governo demonstra interesse em expandir significativamente a área florestal concedida à iniciativa privada, com planos de aumentar essa extensão em até 300%. Como parte desse plano, cinco outras Flonas na região amazônica e uma floresta pública federal não destinada já estão com processos administrativos para a realização de novas concessões com o propósito de promover o MFS (SFB, 2022b).

O Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (Ibama) é a entidade federal responsável por avaliar e, aprovar o Plano de Manejo Florestal Sustentável (PMFS), instrumento norteador da atividade extrativista florestal praticada na Amazônia. Esse plano abrange a caracterização do ambiente físico e biológico, a avaliação dos estoques de recursos e a definição de práticas de exploração alinhadas com a capacidade da floresta (BRASIL, 2006b).

A intensidade máxima de corte permitida nas concessões florestais é de 30 m³/ha, no entanto, existem outros critérios que restringem a exploração, tais como a manutenção de pelo menos 10% das árvores de cada espécie a cada 100 ha e o estabelecimento de diâmetros mínimos de corte baseados em estudos específicos sobre a regeneração natural por espécie (MMA, 2006). É importante também considerar a proteção de espécies raras ou proibidas, bem como a integridade de áreas de preservação permanente e áreas de alto valor para a conservação, seja por suas características ambientais, culturais ou históricas (IBAMA, 2006a).

O ciclo de corte, que é o intervalo de tempo entre colheitas sucessivas de produtos florestais em uma mesma área, varia de 25 a 35 anos no Brasil, tendo como finalidade primordial garantir a regeneração florestal. Isso significa que um empreendimento que adote um ciclo de 30 anos pode planejar a exploração de 30 Unidades de Produção Anual (UPAs). Por meio do documento chamado Plano Operacional Anual (POA), são apresentados pelos

concessionários informações como o inventário florestal georreferenciado, a localização das infraestruturas e o cronograma de trabalho. Esse plano deve ser aprovado pelo Ibama para a emissão da autorização para a exploração florestal, concedida individualmente para cada UPA (MMA, 2006).

Os MFSs realizados em concessões florestais federais empregam um conjunto de técnicas conhecido como Exploração de Impacto Reduzido (EIR). Essas técnicas têm como objetivo minimizar os impactos nas florestas remanescentes, reduzir a degradação do solo e a erosão, preservar a qualidade da água, mitigar os riscos de incêndio e, potencialmente, contribuir para a regeneração e proteção da diversidade biológica (HOLMES et al., 2004). A EIR envolve um planejamento sistêmico da infraestrutura, que inclui estradas, pátios de estocagem e ramais de arraste. Além disso, para minimizar o impacto da queda das copas das árvores sobre a vegetação remanescente, são empregadas técnicas como o corte prévio de cipós e a utilização de planos de corte direcionais (DYKSTRA et al., 1996).

Ellis et al. (2019) com base em dados de campo coletados em 61 blocos amostrais em florestas tropicais, distribuídos em sete países e três continentes, estimou que a emissão de gases de efeito estufa relacionadas à exploração de madeira pode ser reduzida em até 44% com a adoção das técnicas de EIR. Um estudo conduzido na bacia do Congo indica que as emissões de carbono associadas à atividade madeireira poderiam ser reduzidas em até 51% por meio da implementação de técnicas de EIR (UMUNAY et al., 2019).

Estudos conduzidos na Floresta Amazônica indicam que, em comparação com a exploração florestal convencional, as técnicas de EIR resultam em reduções significativas dos impactos ambientais. Por exemplo, reduz o tamanho dos pátios de estocagem de madeira em seis vezes (MONTEIRO, 2005); diminui em cerca de 50% a quantidade de árvores remanescentes danificadas (JOHNS et al., 1996); causa, aproximadamente, metade dos danos ao solo e ao dossel florestal (PEREIRA et al., 2002; ASNER et., 2004) e reduz em dois terços o desperdício de madeira (HOLMES et al., 2004). Um estudo realizado por Mazzei et al. (2010) no estado do Pará destacou que em explorações bem planejadas e conduzidas com baixa intensidade (corte de até três árvores por hectare), a regeneração florestal pode restabelecer completamente o estoque de carbono acima do solo em até 15 anos.

Os contratos de concessão florestal estabelecem determinados indicadores socioambientais que são monitorados pelo SFB ao longo de sua vigência. Esses indicadores incluem investimentos em infraestrutura e serviços para a comunidade local, a geração de empregos na região, o nível de processamento dos produtos nos municípios abrangidos pela

concessão, o apoio e engajamento em projetos de pesquisa, bem como a promoção de políticas afirmativas de gênero (SFB, 2022a). Em caso de descumprimento desses critérios, entre outras penalidades, as atividades podem ser suspensas.

Do ponto de vista das receitas destinadas diretamente ao setor público, as empresas concessionárias comprometem-se a efetuar pagamentos trimestrais ao órgão concedente. No período de 2010 a 2021, aproximadamente 32 milhões de reais foram repassados para os estados e municípios onde as concessões estão localizadas, enquanto 16 milhões foram destinados ao Fundo Nacional de Desenvolvimento Florestal (FNDF)³. Adicionalmente, 32 milhões foram direcionados ao Instituto Chico Mendes de Conservação da Biodiversidade (ICMbio) para custear a gestão e fiscalização das unidades de conservação federais de uso sustentável. Outros 45 milhões permaneceram sob a administração do SFB, responsável pela seleção e gestão dos contratos de concessão florestal (SFB, 2022b).

³ Fundo de natureza contábil destinado a fomentar o desenvolvimento de atividades sustentáveis de base florestal no Brasil e a promover a inovação tecnológica do setor (BRASIL, 2006).

3. MAPEAMENTO DA SUPRESSÃO DE VEGETAÇÃO NA FLORESTA AMAZÔNICA

3.1 USO DE SENSORES ORBITAIS NO MAPEAMENTO FLORESTAL

O desmatamento, também conhecido como corte raso, envolve a remoção completa da cobertura vegetal. Desde 1988, o Instituto Nacional de Pesquisas Espaciais (INPE) opera o Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite (Prodes), visando monitorar o desmatamento na Amazônia Legal Brasileira. Com o uso predominante de imagens de satélite, especialmente do Landsat, especialistas mapeiam áreas desmatadas que ultrapassam 6,25 hectares, fornecendo dados confiáveis que são essenciais para a formulação de políticas públicas na região (INPE, 2022b).

O monitoramento da degradação florestal, quando não há a remoção completa da vegetação, teve início na Amazônia apenas em 2007 com o sistema Degrad, posteriormente substituído pelo Deter B, em 2017. Utilizando imagens semelhantes às do Prodes, o sistema Degrad mapeava áreas de degradação com dimensão mínima de 6,25 hectares, oferecendo taxas anuais de degradação florestal.

O Deter B, não se propõe a inventariar a degradação florestal, pois opera como um sistema de alerta, com foco na rápida detecção de ocorrências de degradação florestal. Ele usa imagens de baixa resolução espacial, mas com alta resolução temporal dos sensores WFI do satélite Cbers 4 e AWiFS do satélite IRS, empregando a técnica de Modelos de Mistura Espectral (MME). Embora os polígonos mapeados possam ter dimensões próximas a um hectare, os resultados divulgados ao público em geral referem-se a áreas com dimensão mínima de 6,25 hectares (INPE, 2017, 2019).

Com o intuito de detectar especificamente a Exploração Seletiva de Madeira (ESM) em áreas de interesse estatal para a implementação de MFS, o Inpe, atendendo a uma demanda do SFB, desenvolveu em 2008 o Sistema de Detecção da Exploração Seletiva (Detex). Esse sistema utiliza imagens dos satélites Landsat e Cbers, empregando a técnica de MME. O Detex tem a capacidade de identificar áreas com solo exposto relacionadas aos pátios de estocagem e, dependendo da intensidade, também pode detectar estradas (PINAGÉ, 2011; RODRIGUES et al., 2019; MAPA, 2021).

O mapeamento do desmatamento na Floresta Amazônica conduzido pelo Inpe com o uso de imagens ópticas orbitais de média resolução, têm desfrutado de uma reputação sólida e ampla aceitação, servindo de base para políticas públicas ao longo de décadas. Esses

resultados têm sido amplamente respeitados pela comunidade científica. No entanto, o mapeamento da degradação florestal enfrenta desafios significativos devido à dificuldade em detectar mudanças que se apresentam mais sutis, quando observadas por imagens com baixa resolução espacial.

A degradação florestal, embora não tenha uma definição amplamente aceita, é geralmente descrita como um processo contínuo de redução dos serviços ecossistêmicos em relação a valores de referência (THOMPSON et al., 2013; FERREIRA et al., 2015; FAO, 2020). Vale ressaltar que, embora a degradação florestal não resulte em uma alteração imediata na cobertura da terra, quando ocorre de forma intensiva, pode levar ao desmatamento (INPE, 2022a). Na Amazônia, as principais formas de degradação florestal incluem mineração, incêndios e a ESM.

Estudo de revisão desenvolvido por Jackson & Adam (2020) demonstrou que sensores ópticos são os mais amplamente utilizados no mapeamento de ESM, seguidos por dados de Radar e Lidar. Para os autores, os métodos de sensoriamento remoto desenvolvidos para detectar ESM em florestas tropicais apenas identificam atividades desenvolvidas com maior intensidade. Estudos apontam que muitos profissionais erroneamente sustentam a concepção de que os métodos usados para medir o desmatamento podem ser aplicados de forma igualmente eficaz à degradação florestal (IPCC, 2019; GAO et al., 2020).

Em condições naturais, a maior parte da renovação das florestas tropicais ocorre através de clareiras pequenas e médias causadas por árvores isoladas ou pequenos grupos de árvores (BROKAW, 1982). O biólogo Herbert Shubart (1983) explica que a formação de clareiras no interior da Floresta Amazônica leva a processos ecológicos que induzem à regeneração florestal, na medida em que o aumento da penetração de luz até o nível do solo, a diminuição da competição de raízes e o aumento temporário da disponibilidade de nutrientes minerais através da decomposição dos troncos e folhas das árvores mortas representam condições que propiciam o desenvolvimento rápido de uma série de plantas, tanto pioneiras como de futuras árvores emergentes da floresta madura.

Diversas pesquisas realizadas em florestas tropicais destacam que as clareiras originadas da atividade de MFS são estruturas altamente dinâmicas e efêmeras, devido ao rápido fechamento do dossel causado pelo crescimento de espécies secundárias de baixa biomassa, como arbustos e trepadeiras. Esse processo altera significativamente as assinaturas espectrais das clareiras dificultando sua identificação por meio de sensores ópticos (PEREIRA et al., 2002; MATRICARDI et al., 2005; MONTEIRO, 2005; SOUZA Jr. et al., 2005;

HEROLD et al., 2011; FRANKE et al., 2012; LANGNER et al., 2016; DE CARVALHO et al., 2017; LIMA et al., 2019; DALAGNOL et al., 2023).

Hunter et al. (2015) estimaram em duas áreas submetidas a ESM na Floresta Amazônica, um ganho médio de altura da vegetação nas clareiras de cerca de um metro por ano. De acordo com Souza Jr. et al. (2005), o fechamento do dossel nas áreas impactadas pela ESM ocorre geralmente em um período de um a dois anos, enquanto Matricardi et al. (2005) sugerem um prazo de um a três anos.

Estudos realizados por Dalagnol et al. (2019, 2023) na Amazônia brasileira, constataram que a maioria das pequenas clareiras se regeneram completamente em cerca de dois anos, enquanto clareiras maiores podem persistir por até cinco anos ou mais. Em estudo desenvolvido em área sob concessão florestal na Flona de Jamari, localizada no estado de Rondônia, Hethcoat et al. (2019), com o uso de imagens Landsat, praticamente não detectaram sinais de exploração no ano seguinte ao término da ESM. Destaca-se que os principais sinais foram identificados somente durante a safra madeireira.

Outro aspecto importante a ser considerado no mapeamento de ESM é o efeito das variações fenológicas das plantas ao longo do tempo. Por exemplo, a perda de folhas durante a estação seca pode causar alterações significativas na resposta espectral dos dosséis, levando a falsas detecções de clareiras (MASILIUNAS, 2017; DALAGNOL et al. 2019).

A dificuldade de mapear clareiras florestais oriundas da ESM é evidente quando examinamos alguns estudos que tratam sobre o tema em florestas tropicais: (READ et al., 2003; ASNER et al., 2004; MONTEIRO, 2005; SOUZA et al., 2005; MATRICARDI et al., 2013; SILVA, 2014; LANGNER et al., 2016; DALAGNOL et al., 2019; HERNANDEZ-GOMEZ et al., 2019; HETHCOAT et al., 2019; AQUINO et al., 2021; OLIVEIRA et al., 2023; WELSINK et al., 2023). Na maioria das pesquisas mencionadas, o objetivo era apenas detectar as clareiras e, com base nesses dados de localização, estimar a área total afetada pela ESM. Por exemplo, Matricardi et al. (2005) calcularam a área total afetada pela ESM com base em raio de influência definida a partir dos pátios de estocagem detectados.

No âmbito do processamento digital de imagens, uma estratégia que se destaca pela sua eficácia na caracterização mais refinada das características espectrais das áreas vegetadas e na potencialização da capacidade de discriminação e interpretação das imagens é a utilização de índices de vegetação (LOS, 2013; LIU et al., 2015; GAO et al., 2020). Esses índices resultam de combinações matemáticas dos valores dos pixels entre diferentes bandas

posicionadas em regiões do espectro eletromagnético mais sensíveis à atividade fotossintética, como as regiões do vermelho e do infravermelho próximo (CRÓSTA, 1992).

A assinatura espectral de áreas cobertas por vegetação é marcada pela baixa refletância na região do vermelho e pela intensa refletância na faixa do infravermelho próximo. Em contraste, elementos como nuvens e água exibem maior refletância no espectro visível do que no infravermelho próximo, enquanto afloramentos rochosos e solos expostos demonstram uma resposta semelhante nessas duas regiões mencionadas (PIAO, et al., 2015).

Segundo Jensen (2009), uma maior quantidade de informação espectral e radiométrica podem auxiliar na avaliação de alvos pelo sensoriamento remoto, possibilitando um ajuste mais robusto dos algoritmos de classificação. Segundo Lu & Weng (2007), a inclusão de dados auxiliares, como índices de vegetação, desempenha um papel crucial na melhoria da precisão das classificações de imagens em ambientes florestais. Dentre os diversos índices de vegetação disponíveis, merece destaque aquele que possivelmente ainda é o mais amplamente utilizado, o Índice de Vegetação da Diferença Normalizada (NDVI) (IPCC, 2019; PARANHOS FILHO et al., 2020).

Gao et al. (2020), com base em 139 artigos publicados entre os anos de 2000 e 2020, constatou que as imagens Landsat foram as mais utilizadas no mapeamento de degradação florestal. No entanto, para Lima et al. (2019), a resolução espacial do Landsat (30m) pode ser insuficiente para identificar distúrbios como os causados pela ESM. Apesar da ampla aplicação das imagens Landsat, sua capacidade é limitada no mapeamento de ESM realizado em baixa intensidade, mesmo quando associada ao uso de métodos poderosos de processamento, como demonstrado no estudo conduzido por Hernandez-Gomez et al. (2019) na Península de Yucatán, no México.

Conforme observado por Read (2003), imagens de média resolução espacial podem ser eficazes na detecção de pátios de estocagem e estradas largas, mas geralmente carecem da resolução necessária para identificar clareiras de exploração, trilhas de arraste e estradas mais estreitas. Segundo Hethcoat et al. (2019), o uso de imagens Landsat é adequado apenas para mapear explorações com intensidade superior a 20 m³/ha.

No estudo realizado por Lima et al. (2019), que abrangeu sete áreas sob MFS no estado do Amazonas, foi realizada uma comparação entre o desempenho das imagens dos satélites Sentinel-2 MSI e Landsat 8 na detecção de alterações sobre o dossel florestais. Os resultados revelaram que a resolução espacial do Sentinel-2 MSI possibilita a identificação mais precisa de distúrbios florestais de menor magnitude. Os autores enfatizam a dificuldade de determinar,

apenas com base nas imagens do Landsat 8, se as áreas mapeadas como não impactadas realmente não possuem quaisquer impactos, destacando a importância da realização de levantamentos em campo para confirmar tais informações.

Esses achados corroboram com os resultados obtidos por Masiliūnas (2017) em áreas florestais na Guiana, os quais indicaram que as imagens Landsat são capazes de detectar apenas pátios de estocagem e estradas mais largas em áreas sob ESM. Todavia, a resolução espacial das imagens Sentinel-2 possibilitou, por sua vez, a detecção da maioria das clareiras florestais.

Read et al. (2003a), ao avaliar áreas sob MFS também no estado do Amazonas, constataram que o uso de imagens do satélite Ikonos, com resolução espacial de um metro, possibilitou a detecção de estradas principais, algumas estradas secundárias, pátios de estocagem e clareiras maiores. No entanto, não foi possível identificar estradas e clareiras de menor dimensão.

Welsink et al. (2023) utilizaram mosaicos mensais compostos por imagens PlanetScope com resolução espacial de 4,77m para realizar avaliação visual da perda de cobertura arbórea associada à ESM. Concluíram que a presença ou ausência de atividades de exploração madeireira é geralmente capturada de forma confiável. Todavia, observaram que pequenos trechos de perda de cobertura arbórea podem ser invisíveis nos mosaicos do PlanetScope, indicando a necessidade de dados com resolução espacial mais elevada para uma análise mais detalhada.

Monteiro (2005) utilizou MME em imagens Landsat, Aster e Ikonos II no mapeamento de infraestrutura madeireira em área sob MFS, observando ganhos progressivos de informação com o refinamento da resolução espacial. A largura das estradas secundárias e as dimensões dos pátios de estocagem só puderam ser identificadas com o uso de imagens Ikonos, que possuíam uma resolução espacial de um metro.

Aquino et al. (2021) realizou experimentos para avaliar a capacidade de sensores ópticos com diversas resoluções espaciais (0,3 m a 30 m) em mapear ESM em florestas tropicais e concluiu que as imagens do WorldView-3 (0,3 m) apresentam muito ruído para detectar alterações significativas. Entretanto, para os autores, resoluções variando de 0,8 m (SkySat) a 10 m (Sentinel-2) são capazes de detectar de forma consistente a atividade madeireira.

Conforme Gao et al. (2020), embora imagens de alta resolução espacial forneçam informações espaciais mais detalhadas, mesmo com esses dados, mapear a Exploração

Seletiva de Madeira (ESM) em baixas intensidades é desafiador. Essas imagens podem enfrentar desafios devido ao impacto mais significativo das sombras causadas pela topografia ou árvores, além de apresentarem alta variação espectral dentro da mesma classe de cobertura (WENG, 2010). Silva (2014) enfrentou dificuldades ao mapear clareiras de exploração em áreas sob MFS utilizando imagens de altíssima resolução espacial, com 0,5 metros (pancromáticas) e dois metros (multiespectrais) dos satélites GeoEye-1 e WorldView-2. Como solução, a autora optou por estimar a abertura do dossel por meio de medições em campo com fotografias.

Uma abordagem eficaz para aumentar a resolução espacial em dados multiespectrais é a aplicação da técnica de fusão de imagens. Essa técnica de realce espacial consiste na criação de imagens coloridas com maior resolução espacial. Isso é alcançado integrando a banda pancromática com informações espectrais mais detalhadas de outras bandas que possuem resolução espacial inferior (Paranhos Filho et al., 2020).

A técnica preserva a resolução espacial da banda pancromática enquanto mantém as características espectrais das bandas multiespectrais. Nesse processo, um novo conjunto de dados é gerado, apresentando informações otimizadas e resultando em imagens mais nítidas e com mais detalhes. Segundo Weng (2010), a fusão de bandas não apenas contribui para análises mais eficientes e precisas, como também se revela particularmente valiosa em tarefas de classificação de imagens, onde a habilidade de discernir entre diferentes tipos de objetos e terrenos é fundamental.

3.2 MAPEAMENTO DA EXPLORAÇÃO SELETIVA DE MADEIRA COM SENSOR LIDAR

A tecnologia Lidar utiliza scanners que empregam lasers para emitir milhares de pulsos infravermelhos por segundo em direção à superfície. Ao medir o tempo entre a emissão e o retorno dos pulsos ao sensor, é possível calcular as distâncias, propiciando a criação de representações tridimensionais (GIONGO et al., 2010).

A capacidade dos pulsos de laser do Lidar de penetrar em pequenas aberturas do dossel florestal possibilita a obtenção de informações altimétricas do relevo, bem como a análise da estratificação vertical da floresta, permitindo o cálculo de diversas medidas. De acordo com Read et al. (2003), os dados Lidar aerotransportados são úteis para avaliar e validar quantitativamente alterações florestais.

Koetz et al. (2007) destacam que a comparação entre dados Lidar e imagens ópticas revela que os primeiros são especialmente indicados para a avaliação da estrutura tanto horizontal quanto vertical das florestas, enquanto as imagens ópticas se destacam pela riqueza de informações relacionadas às propriedades biofísicas e químicas do dossel. Além disso, os autores ressaltam que os dados Lidar oferecem medidas diretas da estrutura florestal, eliminando a necessidade de cálculos ou estimativas adicionais. Isso proporciona um valor numérico preciso e imediato para a grandeza em questão, simplificando a análise.

Os sensores Lidar aerotransportados apresentam ótimos resultados em obter medidas da estrutura florestal em áreas sob ESM (D'OLIVEIRA et al., 2012; SILVA, 2014; ELLIS et al., 2016; DE CARVALHO et al., 2017; LOCKS, 2017; DALAGNOL et al., 2019; LOCKS & MATRICARDI, 2019). Em experimento conduzido por Locks (2017), foi observado que 90% da infraestrutura de exploração florestal mapeada com dados Lidar coincidia com os dados coletados em campo. Similarmente, em dois estudos conduzidos na Indonésia (ELLIS et al., 2016; MELENDY et al., 2018), os autores concluíram que a utilização de dados provenientes de sensores Lidar se equiparavam às medições realizadas em campo.

No amplo estudo conduzido por Matricardi & Locks (2019) em 21 UPAs distribuídas em três Flonas sob concessão florestal na Amazônia, foi concluído que o uso de Lidar é eficaz para monitorar os impactos da ESM em áreas com menor intensidade de degradação. Segundo os autores, os resultados obtidos demonstraram uma concordância significativa com as medições de campo, destacando a confiabilidade dessa tecnologia na avaliação dos impactos florestais.

4. CLASSIFICAÇÃO DE IMAGENS

A classificação de imagens é um procedimento de extração de informações que visa identificar padrões e elementos uniformes nas imagens (INPE, 2006a). Esse processo pode ser conduzido de maneira supervisionada, utilizando amostras de treinamento fornecidas pelo usuário para definir os padrões de comportamento espectral de cada classe, ou de maneira não supervisionada, na qual os classificadores identificam autonomamente as classes (IBGE, 2001).

Na abordagem convencional denominada "Pixel a Pixel", cada unidade de imagem é examinada de forma independente, levando em conta apenas suas propriedades espectrais e desconsiderando a informação espacial ao seu redor. Nesse cenário, a classificação é executada isoladamente para cada pixel, configurando-o como a menor unidade de análise no processo.

Os métodos de classificação fundamentados em pixels impulsionaram de maneira significativa o avanço contínuo das técnicas de análise de imagens de sensoriamento remoto (HAO et al., 2021). No entanto, segundo Lourenço et al. (2021), ao lidar com objetos terrestres em áreas de características complexas, os pixels não podem mais ser considerados como o único fator relevante na análise de imagens e extração de informações. A abordagem baseada em pixels enfrenta desafios, especialmente em regiões com transições abruptas entre diferentes classes, onde a ausência de contexto espacial pode resultar em limitações na precisão da classificação (ibid.).

A concepção de incluir informações contextuais na classificação de imagens remonta à década de 1970, porém, sua relevância aumentou significativamente com a crescente disponibilidade de imagens de alta resolução espacial observada nas últimas décadas (BLASCHKE, 2009). A classificação baseada em objetos geográficos é fundamentada no princípio, conforme expresso por Baatz & Schäpe (2000), de que informações semânticas importantes para entender uma imagem não são, na maioria dos casos, representadas em pixels únicos, mas em objetos de imagem significativos e suas relações mútuas.

Blaschke (2009) sugere que a seleção da técnica de classificação mais adequada depende da relação entre a resolução espacial das imagens e o tamanho dos objetos a serem mapeados, conforme se segue:

- (a) baixa resolução: pixels significativamente maiores que os objetos, recomenda-se técnicas de sub-pixel;

- (b) resolução média: pixels e tamanhos de objetos são da mesma ordem, técnicas Pixel a Pixel são apropriadas;
- (c) alta resolução: os pixels são significativamente menores que o objeto, é necessária a regionalização dos pixels (ibid., 2010, p. 3).

Todavia, em pesquisas realizadas por Johnson & Ma (2020) e Kotaridis & Lazaridou (2021) abrangendo centenas de artigos científicos publicados entre os anos de 2018 a 2020 sobre segmentação de imagens e Geobia, observou-se que dados Sentinel e Landsat estavam frequentemente associados a essas técnicas. Isso sugere que a Geobia ultrapassou seu foco inicial, que se baseava em dados ópticos com alta resolução espacial.

De acordo com Hay & Castilla (2008), a organização de uma imagem em objetos assemelha-se à maneira como os seres humanos percebem e compreendem a paisagem. De acordo com Blaschke et al. (2000), nossa percepção do conteúdo de uma imagem é baseada predominantemente em objetos, que uma vez percebidos, são conectados por meio de uma intrincada rede, moldada pela experiência e pelo conhecimento.

4.1 SEGMENTAÇÃO DE IMAGENS E ALGORITMO LARGE-SCALE MEAN-SHIFT (LSMS)

A Geobias é uma técnica que envolve a divisão de uma imagem com base em atributos espectrais e espaciais, resultando em um conjunto de regiões mutuamente disjuntas, conhecidas como segmentos (ULLOA & HERZSPRUNG, 2020). Diversos algoritmos de segmentação têm sido empregados em imagens de sensoriamento remoto, conforme destacado por Blaschke et al. (2000), Johnson & Ma (2020) e Kotaridis & Lazaridou (2021). Neste estudo, iremos destacar o algoritmo de Segmentação Large-Scale Mean-Shift (LSMS).

Em essência, o LSMS pode ser compreendido como um método de estimativas de densidade de probabilidade. Desenvolvido por Michel et al. (2015), o LSMS é uma derivação do método não paramétrico proposto por Fukunaga & Hostetler (1975). Mas a extensão deste algoritmo para conjuntos espaciais/espectrais foi proposta inicialmente por Comaniciu & Meer (2002). Optamos por esse algoritmo em função de sua disponibilidade no Qgis, por ser amplamente testado amplamente utilizado em diversas aplicações em sensoriamento remoto (XIAO et al., 2012; IMMITZER et al., 2016; EINZMANN et al., 2017; DE LUCA et al., 2019; ROODPOSHTI et al., 2019; SOUSA-HERRERA et al., 2019; DUARTE et al., 2020; RAJ & SRINIVASULU, 2020; BOZKURT, 2021; LOURENÇO et al., 2021; MODICA et al., 2021; KILLEEN et al., 2022). Além disso, o LSMS apresenta segundo a literatura supracitada, menos dependência dos parâmetros de ajuste. Enquanto alguns métodos de segmentação, como o proposto por Baatz & Schäpe (2000) podem exigir ajustes cuidadosos de vários parâmetros para obter resultados satisfatórios, o LSMS tende a ser menos dependente de ajustes manuais. Isso torna seu uso mais direto e menos suscetível a erros devido a possíveis configurações inadequadas.

Segundo Killeen et al. (2022), ao utilizar o valor médio de número digital do segmento, a confusão na etapa de classificação é reduzida, uma vez que a variância dentro do objeto é diminuída. De acordo com Roodposhti et al. (2019), o algoritmo demonstra-se robusto o suficiente para lidar com valores discrepantes. Michel et al. (2015) ressalta a eficácia do LSMS em uma ampla gama de dados geoespaciais, cobrindo diversas resoluções espaciais. Para os autores, sua disponibilidade como código aberto, versatilidade e simplicidade são fatores cruciais para sua crescente popularidade.

O LSMS é fundamentado em três parâmetros principais para seu funcionamento: Raio da Vizinhança Espacial (RVE), Raio de Alcance Espectral (RAE) e Tamanho Mínimo do Segmento (TMS). O RVE define a distância máxima para construir o segmento a partir da

média dos pixels analisados. O RAE estabelece o limite na distância euclidiana da assinatura espectral para considerar pixels como parte do mesmo segmento. Já o TMS determina que, se após a segmentação, um segmento tiver um tamanho inferior a esse critério, ele é mesclado à região que possua a assinatura espectral mais próxima (DE LUCA et al., 2019; MODICA et al., 2021; ORFEO, 2023).

Todavia, fica explícito ao consultar a literatura que a técnica de segmentação não se configura como um processo completamente automatizado, e que não há uma fórmula geral para segmentar os objetos de uma imagem com sucesso. Ou seja, nenhuma parametrização específica é adequada para todas as tarefas e objetivos (GONÇALVES et al., 2019; DUARTE et al., 2020; BOZKURT, 2021; KOTARIDIS & LAZARIDOU, 2021).

Neste contexto, é crucial comparar diversos ajustes dos parâmetros disponíveis para perceber qual deles é mais adequado. Segundo Bozkurt (2021), a segmentação continua a ser um procedimento altamente interativo e subjetivo, parâmetros de segmentação apropriados são cruciais para alcançar bons resultados, todavia, constitui-se ainda uma tarefa desafiadora, já que depende fortemente de uma base empírica, ou seja, das características específicas da imagem e do objetivo do estudo, bem como do tipo de algoritmo utilizado.

Com base em uma extensa revisão de artigos acerca de segmentação de imagens, Kotaridis & Lazaridou (2021) verificaram que em cerca de 50% dos artigos consultados, os métodos de avaliação da segmentação dependeram de interpretação visual e concluíram que este processo continua a ser altamente interativo, envolvendo abordagens subjetivas de tentativa e erro. Tal conclusão corrobora com a posição expressa por Baatz & Schäpe (2000, p. 04) de que: “Nenhum resultado de segmentação - mesmo que comprovado quantitativamente - irá convencer, se não satisfizer o olho humano”.

Conforme destacado por Lourenço et al. (2021), na segmentação de imagens, a criação de objetos deve ser realizada de maneira a maximizar a variabilidade entre eles e minimizar a variabilidade dentro de cada objeto. Bozkurt (2021) e Kotaridis & Lazaridou (2021) destacam dois desafios frequentes no processo de segmentação de imagens de sensoriamento remoto: a supersegmentação e a subsegmentação. A supersegmentação ocorre quando um objeto na paisagem é dividido em segmentos distintos, indicando a necessidade de uni-los. Por outro lado, a subsegmentação ocorre quando um segmento engloba objetos de classes diferentes, exigindo, assim, a sua divisão durante o processo de classificação. Os autores ressaltam que, de maneira geral, a subsegmentação é mais problemática do que a supersegmentação, uma

vez que os erros resultantes da subsegmentação não podem ser corrigidos durante a classificação da imagem.

A subsegmentação impacta a precisão da classificação, aumentando a probabilidade de que duas ou mais coberturas de solo sejam agrupadas em um único objeto de imagem, gerando assim erros de Comissão (PHIRI & MORGENROTH, 2017). Uma segmentação eficaz, portanto, busca minimizar a supersegmentação e eliminar a subsegmentação (KOTARIDIS & LAZARIDOU, 2021). Com base nessas premissas, realizamos a seleção dos melhores ajustes para os processos de segmentação neste estudo.

4.2 CLASSIFICADORES BASEADO EM APRENDIZAGEM DE MÁQUINA

A Aprendizagem de Máquina (AM) é uma subdivisão da inteligência artificial que se concentra no desenvolvimento de algoritmos e técnicas que permitem que sistemas computacionais aprendam a partir de dados e melhorem seu desempenho em tarefas específicas (LUDERMIR, 2021). A classificação supervisionada de imagens com algoritmos de AM pode ser considerada um processo de aprendizado, pois, procura-se entre diversas hipóteses as que o algoritmo é capaz de gerar com melhor capacidade de descrição do domínio (LORENA & CARVALHO, 2007).

Os algoritmos de classificação baseados em AM são considerados “aproximadores universais”, pois aprendem o comportamento subjacente de um sistema com base em um conjunto de dados de treinamento (LARY et al., 2016, p.4). Classificadores de imagens baseados em AM são métodos não paramétricos, o que significa que eles não fazem suposições sobre a distribuição de frequência dos dados, ou seja, são modelos empíricos e não determinísticos, ao contrário dos classificadores paramétricos tradicionais.

Devido ao fato de que dados de sensoriamento remoto raramente seguem distribuições normais, os métodos não paramétricos têm se tornado cada vez mais populares, pois geralmente oferecem um desempenho melhor em comparação com os classificadores paramétricos (FRIEDL & BROADLEY, 1997; YU et al., 2014; LAWRENCE & MORAN, 2016; BELGIU & DRAGUT, 2016; KHATAMI et al., 2016; LI et al., 2016; MAXWELL et al., 2018; LOURENÇO et al., 2021).

Apesar de serem reconhecidamente mais eficazes, os classificadores não paramétricos nem sempre são os mais utilizados. Em uma pesquisa realizada por Yu et al. (2014), que analisou 1.651 artigos relacionados ao mapeamento do uso da terra, constatou-se que o método

paramétrico Maximum-Likelihood Classifier (MLC) foi o mais frequente, presente em 534 trabalhos.

Khatami et al. (2016) conduziram uma comparação em pares da acurácia dos classificadores utilizados em 266 artigos de mapeamento do uso da terra, publicados ao longo de 15 anos. Nos comparativos realizados, o classificador MLC demonstrou uma acurácia geral inferior a todos os outros métodos não paramétricos com os quais foi confrontado. A prevalência do MLC não se deve apenas à sua facilidade de utilização e à ampla disponibilidade em softwares comerciais, mas também às incertezas associadas à eficácia dos métodos não paramétricos, conforme destacado por Maxwell et al. (2018).

Todavia, destaca-se que não há um consenso sobre qual é o melhor algoritmo para classificação de imagens de sensoriamento remoto. Para Lawrence & Moran (2015), é importante comparar vários métodos para avaliar qual apresenta o melhor desempenho para um determinado conjunto de dados e objetivo de análise. De acordo com Maxwell et al. (2018), o classificador e os parâmetros de ajustes ideais provavelmente serão específicos para cada caso, pois variam em função das classes mapeadas, do tipo de dados, da qualidade do treinamento, bem como das variáveis preditoras.

Neste estudo, foram avaliados os classificadores não paramétricos Random Forest (RF), K-Nearest Neighbors (K-NN) e Support Vector Machine (SVM). A seleção desses três algoritmos de classificação foi motivada pela sua disponibilidade no QGIS, assim como pelo seu extenso histórico de testes e pela consistência dos resultados obtidos com imagens de sensoriamento remoto (YU et al., 2014; KHATAMI et al., 2016; LARY et al., 2016; LI et al., 2016; MAXWELL et al., 2018; THAN NOI & CAPAS, 2018; ZIEGELMAIER NETO, 2022). Cada um desses algoritmos possui lógicas de aprendizagem distintas, representando um conjunto significativo de métodos não paramétricos para classificação de imagens de sensoriamento remoto.

Embora o Algoritmo Decision Tree (DT) também atenda aos requisitos mencionados, decidimos priorizar o RF, uma vez que testarmos classificações com RF com apenas uma árvore de decisão é semelhante a classificar dados com o algoritmo DT. Além disso, a facilidade de ajuste dos parâmetros do RF, K-NN e SVM torna a pesquisa mais reproduzível em comparação com algoritmos mais complexos em termos de ajustes dos parâmetros, como o Artificial Neural Network (ANN). É importante ressaltar que limitações de tempo impediram a realização de testes com um número maior de classificadores, o que resultaria

em mais classificações e exigiria mais tempo para processamento, validação e tabulação dos resultados.

4.2.1 Random Forest (RF)

A Decision Tree (DT) é uma abordagem que estabelece regras para a tomada de decisões, em que a estrutura da árvore representa as divisões e as folhas representam as classes associadas a essas decisões. No entanto, segundo Cánovas et al. (2017), as DTs são sensíveis a pequenas variações nos dados de treinamento, o que pode resultar em alta variância nos resultados. Por outro lado, o algoritmo Random Forest (RF) foi desenvolvido para lidar com esse problema, aproveitando a sabedoria coletiva das árvores para protegê-las de erros individuais (YIU, 2019).

RF é um conjunto de DTs independentes que trabalham coletivamente para atribuir uma classe com base na decisão majoritária das árvores individuais (Figura 01) (MAXWELL et al., 2018; YIU, 2019; IBM, 2020). A baixa correlação entre as árvores é essencial para evitar erros sistemáticos. Maxwell et al. (2018) destacam que a robustez da classificação com o RF se deve à capacidade de cada árvore treinar em um subconjunto aleatório dos dados de treinamento.

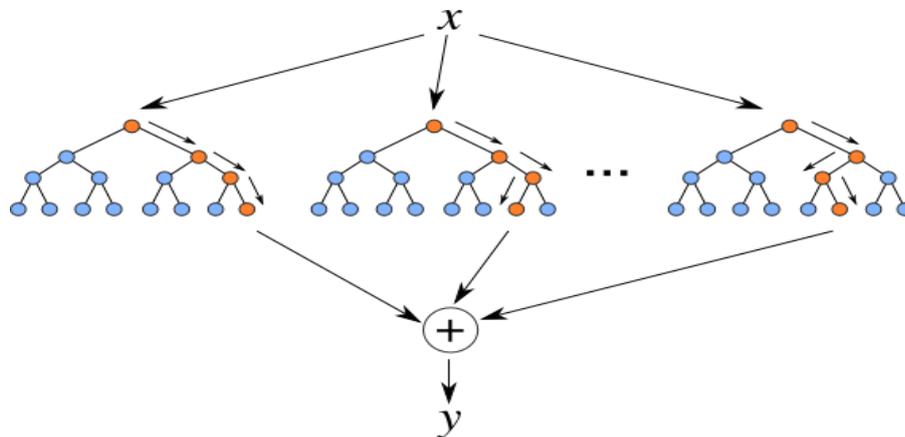


Figura 01. Algoritmo Random Forest (SINGH, 2020).

Em uma análise abrangente realizada por Lawrence & Moran (2015), que incluiu 30 conjuntos de dados, o RF demonstrou a maior acurácia média (73,19%) em comparação com outros cinco classificadores baseados em AM. Em um estudo conduzido por Khatami et al. (2016), o RF superou a DTs em nove artigos, resultando em um aumento médio de 4,0% na acurácia geral. Em uma avaliação de métodos de classificação em Geobia feita por Li et al. (2016), o RF apresentou o melhor desempenho entre os classificadores testados em imagens de alta resolução espacial. O RF possui dois principais parâmetros ajustáveis: a quantidade de árvores e o número de variáveis aleatórias em cada divisão. Segundo Li et al. (2016), é

recomendável utilizar muitas árvores e um pequeno número de variáveis para reduzir a correlação entre as árvores e melhorar a capacidade de generalização

4.2.2 K-Nearest Neighbors (K-NN)

O algoritmo K-NN é notável por sua simplicidade de implementação e compreensão, tornando-se uma escolha popular em tarefas de classificação (PACHECO, 2017). Diferentemente de outros classificadores mais sofisticados, como RF e SVM, o K-NN não cria um modelo de previsão. Em vez disso, ele compara diretamente cada amostra desconhecida com todos os dados de treinamento originais (LI et al., 2016).

Uma característica notável do K-NN é a necessidade de armazenar todo o conjunto de treinamento em memória e calcular as distâncias entre todas as amostras. À primeira vista, essa característica poderia levantar preocupações sobre custos computacionais mais elevados, no entanto, em testes conduzidos por Maxwell et al. (2018), não foram observados problemas significativos de custo computacional à medida que o número de amostras aumentava. Isso sugere que o K-NN pode ser eficiente em termos de recursos computacionais, tornando-o uma opção viável mesmo em conjuntos de dados maiores.

O parâmetro "K" é fundamental no K-NN, pois define o número de amostras vizinhas a serem consideradas para tomar uma decisão de classificação. Por exemplo, conforme Figura 02, ao definir $K=7$, o algoritmo avaliará as classificações das sete amostras mais próximas da nova a ser rotulada, se a maioria dessas pertencer à classe "A", a nova amostra será classificada como "A".

A escolha do valor de K deve equilibrar a maior complexidade dos limites de decisão oriundos de baixos valores de K, com a maior generalização obtidos como maiores valores de K, o que, por sua vez, exige um aumento no esforço computacional (MAXWELL et al., 2018). Apesar de sua simplicidade, o K-NN pode superar classificadores mais complexos, como demonstrado por Khatami et al. (2016). É relevante destacar que o K-NN é amplamente utilizado em Geobias, sendo o método mais comumente utilizado no software eCognition, especializado em análises baseadas em objetos geográficos (LI et al., 2016).

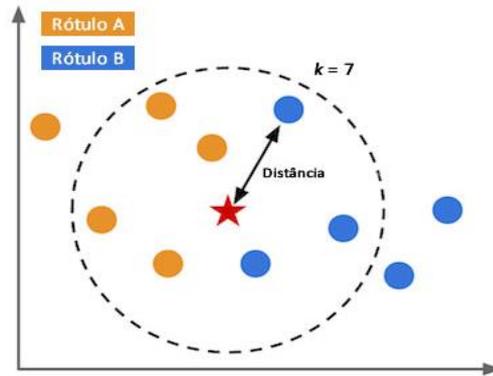


Figura 02. Algoritmo K-NN (PACHECO, 2017).

4.2.3 Support Vector Machine (SVM)

O SVM é um método de aprendizagem, que inerentemente binário, visa identificar a melhor fronteira, chamada de hiperplano que seja linearmente separável entre duas classes em um conjunto de dados. As amostras mais próximas ao hiperplano, portanto, as mais difíceis de classificar, são chamadas de vetores de suporte e dão nome ao algoritmo. Dessa forma, os cálculos das previsões envolvem apenas essas amostras e não todo o conjunto de treinamento, como é realizado com o K-NN (Figura 03) (CORTES & VAPNIK, 1995; MAXWELL et al., 2018).

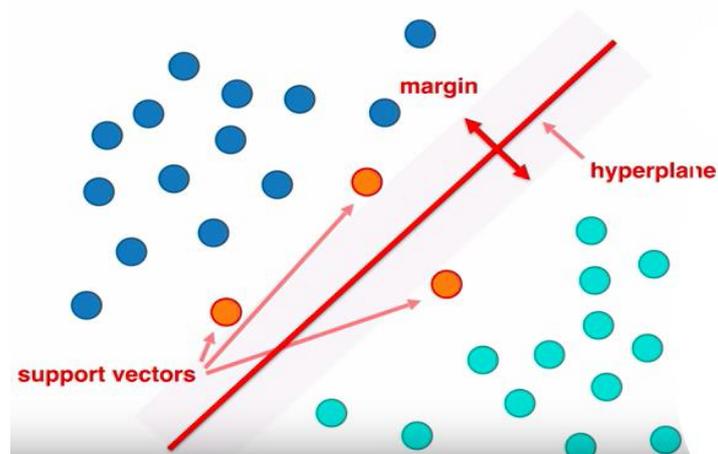


Figura 03. Algoritmo SVM (VAZ, 2018).

A distância entre os vetores de suporte e o hiperplano é chamada de margem, o SVM trabalha com o princípio da maximização da margem, ou seja, a fronteira mais distante dos dados de treinamento será a mais bem desenvolvida. O SVM objetiva encontrar um objeto separador de classes que pode ser uma reta em um espaço bidimensional, um plano em um espaço tridimensional, ou um hiperplano em um espaço n-dimensional de atributos (REMIGIO, 2020).

Para conjuntos de dados que não podem ser separados linearmente, o SVM recorre a funções de kernel para aumentar a dimensionalidade do espaço (Figura 04). Essa estratégia se baseia no Teorema de Cover, que postula que problemas de classificação complexos são mais propensos a serem separáveis linearmente em espaços de maior dimensionalidade (SANTOS, 2002). Embora o SVM seja inerentemente binário, ele lida com problemas de várias classes por meio de abordagens como "one-vs.-one" ou "one-vs.-all" (REMIGIO, 2020).

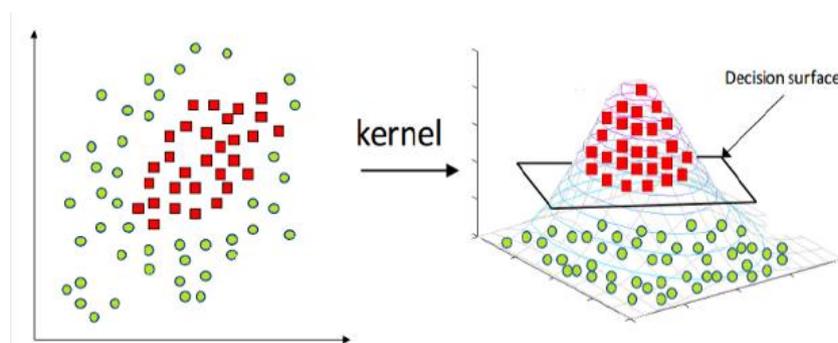


Figura 04. Transformações de Kernel (REMIGIO, 2020).

Uma característica notável do SVM é sua capacidade de tolerar amostras de treinamento que estejam no lado incorreto da margem de decisão. O parâmetro "C" controla a flexibilidade da margem, com valores maiores resultando em margens mais estreitas e menos violações, e valores menores resultando em margens mais largas e mais violações (CORTES & VAPNIK, 1995; MAXWELL et al., 2018; VARGAS JUNIOR, 2020).

No estudo de revisão conduzido por Khatami et al. (2016), o SVM demonstrou o melhor desempenho em termos de acurácia geral entre todos os outros classificadores avaliados em um conjunto de 266 artigos. Além disso, entre os classificadores não paramétricos analisados em 1.651 artigos por Yu et al. (2014), o SVM se destacou pela maior acurácia geral média nos experimentos examinados. Em um estudo realizado por Ziegelmaier Neto (2022) para classificar estágios de sucessão da Floresta Atlântica, o algoritmo SVM foi o que apresentou melhores resultados para as imagens Sentinel-2 e Landsat-8. Resultados semelhantes foram encontrados por Than Noi & Capas (2018) ao comparar os algoritmos K-NN, RF e SVM no mapeamento de uso da terra no Delta do Rio Vermelho, no Vietnã com imagens Sentinel-2. O SVM produziu a maior acurácia geral com a menor sensibilidade aos tamanhos das amostras de treinamento, seguido consecutivamente por RF e K-NN. Por fim, é relevante destacar que o SVM é um dos classificadores não paramétricos mais frequentemente utilizados em estudos em geociências (LARY et al., 2016).

5. ÁREA DE ESTUDO

O estado do Pará lidera o desmatamento na Amazônia brasileira desde o ano 2006, (INPE, 2022a). Altamira, município que abrange 70% da área da Flona homônima, registrou o maior índice de desmatamento na Amazônia entre 2020 e 2021, enquanto Itaituba, que representa 25% da área da Unidade de Conservação (UC), ficou em oitavo lugar nessa lista (INPE, 2022c). O desmatamento na Flona de Altamira tem aumentado nos últimos anos, culminando em uma perda florestal de 11.503,70 hectares entre os anos de 2019 e 2021. Entretanto, é crucial observar que apenas 3,53% dessa área desmatada está localizada em área sob concessão florestal. No ano de 2022, mais 2.800 hectares foram desmatados na Flona de Altamira, mas não houve registro de desmatamento nas áreas concedidas (ibid.).

A Floresta Nacional de Altamira, estabelecida em 1998, abrange uma área de mais de 725 mil hectares no interflúvio dos rios Xingu e Tapajós. Ela faz parte do mosaico de UCs conhecido como "Mosaico Terra do Meio". Sua criação ocorreu no contexto da formulação de políticas públicas que visava o desenvolvimento econômico da região, a prevenção de conflitos fundiários e a contenção do desmatamento e da degradação ambiental, através da criação de polos industriais baseados na utilização sustentável dos recursos naturais (BRASIL, 1998; RIOS, 2007). A Fundação Nacional dos Povos Indígenas (Funai) também recomendou a criação da Flona de Altamira como uma medida de proteção às Terras Indígenas Xipaya e Curuaya (ICMBio, 2012a).

O Plano de Manejo da UC, aprovado em dezembro de 2012, inicialmente destinava 61,81% da área total da UC ao uso sustentável dos recursos florestais, mas essa área foi reduzida para 45% (ICMBio, 2012). Em 2013, foi autorizada a publicação de um edital de licitação para a concessão de quatro Unidades de Manejo Florestais (UMF), abrangendo, inicialmente, um total de 361.917,00 hectares (atualmente reduzido para 326 mil ha) (MMA, 2013). As atividades de exploração começaram em 2016 nas UMFs II e III, e, em 2017, nas UMFs I e IV (SFB, 2022b).

As UMFs compreendem o espaço onde as concessões florestais ocorrem. As Unidades de Produção Anual (UPAs), por sua vez, são subdivisões das UMFs destinadas a serem exploradas em um ano. A área de trabalho desta pesquisa é a UPA 4D que possui 2.976,30 hectares, localizada na UMF IV e que esteve sob exploração florestal entre 14/05/2020 e 14/05/2021 (Figura 05).

Levando em consideração que todos os dados de sensoriamento remoto utilizados foram adquiridos após a conclusão da atividade madeireira, é relevante destacar que a empresa

concessionária registrou nos sistemas oficiais de controle um volume médio explorado na UPA 4D de 8 m³/ha (PATAUA, 2021). À título de referência, conforme exposto no Capítulo 02, a intensidade máxima de corte permitida nas concessões florestais é de 30 m³/ha (IBAMA, 2006a).

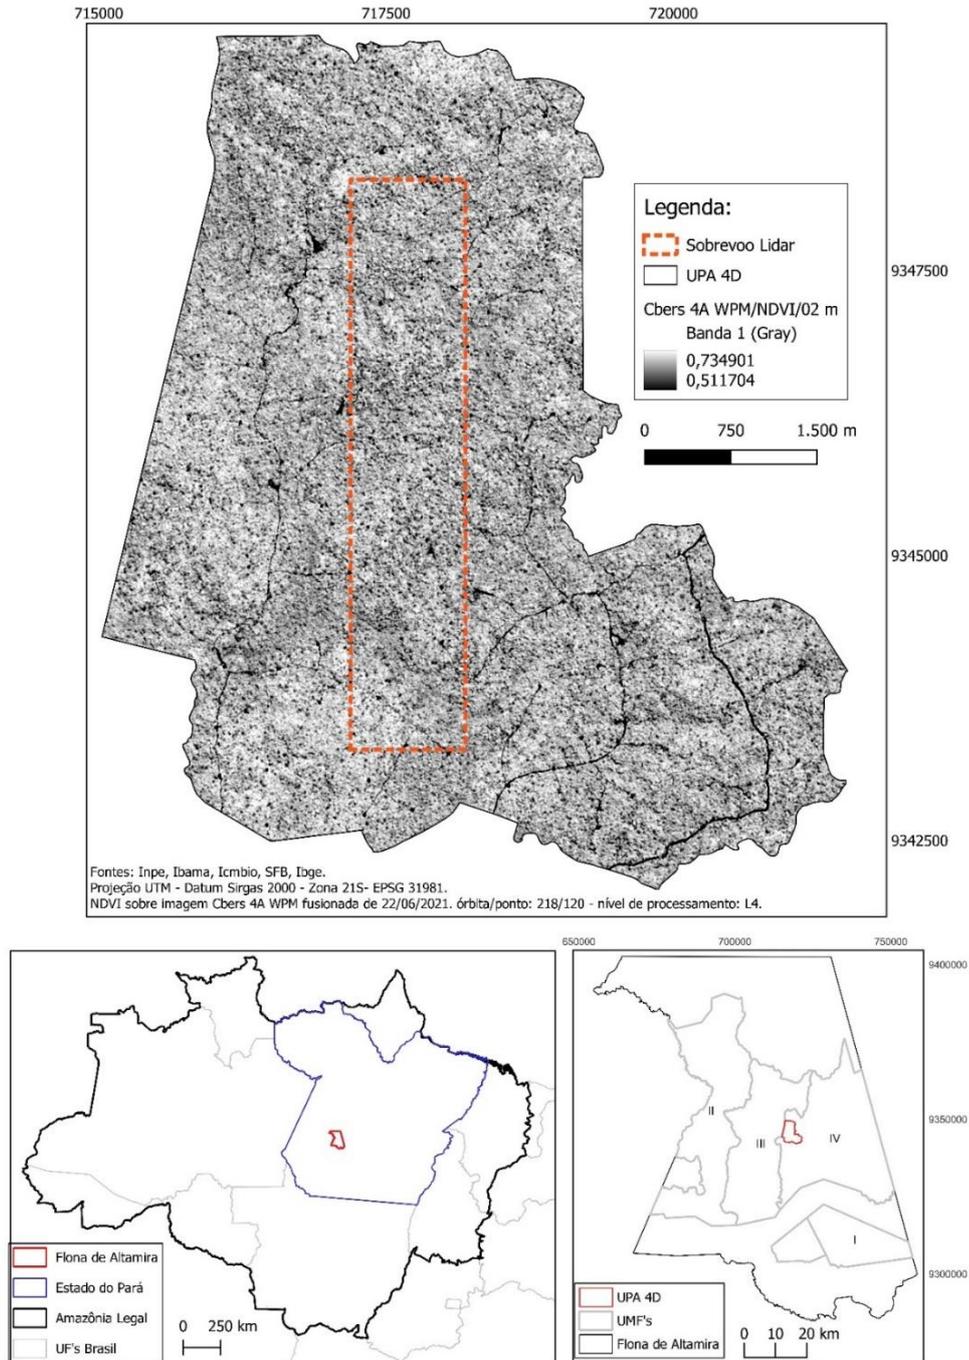


Figura 05. Área de Trabalho e Área de Controle (sobrevoe com Lidar).

De acordo com a classificação climática de Köppen, adaptada ao território brasileiro por Alvares et al. (2013), a UPA 4D encontra-se na zona Am, que corresponde a um clima tropical úmido ou subúmido. No ano de 2013, a média da precipitação total anual nos três

municípios que compreendem a Flona de Altamira foi de 2.622,75 mm. É importante notar que essa precipitação não está distribuída uniformemente ao longo do ano, sendo que 73,55% dela ocorre entre os meses de novembro e abril.

Do ponto de vista geomorfológico, a UPA 4D está completamente inserida na unidade denominada Depressão do Jamanxim – Xingu, que faz parte do domínio morfoestrutural Crátons Neoproterozóicos, conhecido na Amazônia como Terras Firmes (IBGE, 2006). Essa unidade geomorfológica apresenta um nível de aplainamento de idade pleistocênica, com relevo caracterizado por colinas e uma variação altimétrica média entre 180 e 200 metros. O padrão de drenagem é subdendrítico e subortogonal (ibid.). Essas características tornam os relevos dessa unidade especialmente propícios para a ocupação e o desenvolvimento de atividades de MFS (ICMBio, 2012).

De acordo com informações do SFB (2013), os solos na Flona de Altamira são predominantemente de textura argilosa. A Embrapa identifica dois tipos de solos na UPA 4D e em toda a Flona: PVAd49 (Argissolos Vermelho-Amarelos Distróficos + Argissolos Vermelho-Amarelos Eutróficos + Neossolos Litólicos Distróficos) e PVAd31 (Argissolos Vermelho-Amarelos Distróficos + Latossolos Vermelho-Amarelos Distróficos + Neossolos Litólicos Distróficos) (EMBRAPA, 2011).

A formação florestal predominante na UPA 4D (87,77%), de acordo com a classificação do Instituto Brasileiro de Geografia e Estatística (IBGE, 2021), é a Floresta Ombrófila Densa Submontana com Dossel Emergente. Essa floresta é caracterizada por sua vegetação perene, sem uma estacionalidade acentuada (IBGE, 2012). O dossel da floresta atinge alturas entre 30 e 35 metros, sendo denso e compacto, o que resulta na interceptação de grande parte da energia solar, permitindo que apenas cerca de 5% dela alcance o chão da floresta (ICMBio, 2012).

Em 12,23% da área da UPA 4D, conforme a classificação do IBGE (2021), a vegetação é classificada como Floresta Ombrófila Aberta Submontana com Cipós. Essa floresta se caracteriza por ter árvores espaçadas e representa uma transição entre a Floresta Amazônica e as regiões fora da Amazônia (IBGE, 2012). No sul do estado do Pará, a presença de cipós lhe confere o nome popular de "Mata de Cipós". Conforme relatado pela concessionária, a Floresta Ombrófila Aberta na Flona de Altamira possui árvores de menor estatura, atingindo no máximo vinte metros de altura. Os troncos frequentemente apresentam formas tortuosas e cicatrizes causadas por lianas espessas. Como resultado, essa floresta apresenta um potencial econômico menor para a exploração madeireira (PATAUÁ, 2015).

6. MATERIAIS E MÉTODOS

Todos os processamentos foram realizados no software livre QGIS (versão 3.22.5-Białowieża). Os algoritmos utilizados nas classificações das imagens estão disponíveis no complemento Orfeo Toolbox (OTB) (GRIZONNET et al., 2017). Os modelos tridimensionais gerados a partir dos dados Lidar foram realizados com o complemento Open Lidar Toolbox (EICHERT et al., 2022).

No que se refere aos dados em formato vetorial, além da delimitação da UPA 4D, também foram utilizados dados da localização dos canais de drenagem e da infraestrutura instalada, esta última, abrangendo estradas principais, secundárias e pátios de estocagem. Esses dados foram obtidos com base em informações fornecidas pela empresa concessionária, responsável pela execução do MFS.

A delimitação dos canais de drenagem é apresentada em formato de polígonos e foi produzida pelo concessionário utilizando Modelo Digital de Terreno (MDT), gerado a partir do processamento de dados de radar do satélite Alos, com confirmação em campo (PATAUÁ, 2019). A localização da infraestrutura instalada foi obtida a partir de dados coletados em campo pela empresa concessionária e foram apresentados aos órgãos de controle após a conclusão das atividades de exploração florestal na UPA 4D (ibid., 2021). Os dados vetoriais que indicam a localização das infraestruturas instaladas foram disponibilizados em formato de linhas para as estradas e em formato de pontos para os pátios de estocagem. Vale ressaltar que todos esses dados vetoriais estão acessíveis por meio do Sistema Nacional de Controle da Origem dos Produtos Florestais (Sinaflor).

Os principais recursos utilizados para conduzir a pesquisa consistem em imagens ópticas orbitais, as quais são detalhadas na Tabela 01, acompanhadas de um resumo das características mais significativas de cada uma delas.

Satélite	Sensor	Data	Bits	Resol. Espectral	Resol. Espacial	Resol. Temp.	Nível
Cbers 4A	WPM	22/06/21	10	4 bandas + Pan	2 m (pan) 8 m (multi)	31 dias	L4
Sentinel-2	MSI	30/06/21	12	13 bandas	10 m, 20 m e 60 m	5 dias	2A
PlanetScope	PSB.SD	22/06/21	16	8 bandas	3 m	1 dia	Analytic SR

Tabela 01. Características gerais dos sensores ópticos.

As imagens provenientes da constelação PlanetScope são obtidas por mais de cem satélites operando a uma altitude média de quinhentos quilômetros, possibilitando a cobertura diária de todo o território nacional com sensores idênticos (REDE MAIS, 2023). Cada imagem

multiespectral do PlanetScope cobre uma área de 24×8 km. O produto na versão Analytic SR, utilizado após ortorretificação, com superfície de reflectância e erro posicional inferior a dez metros (PLANET TEAM, 2022). Em uma avaliação realizada por Pinheiro et al. (2021), a acurácia posicional das imagens PlanetScope foi examinada em relação a um mosaico de ortofotos com 10 cm de resolução espacial, revelando um erro médio de 4,65 metros. As bandas espectrais e seus comprimentos de onda correspondentes estão detalhados na Tabela 02.

Bandas Espectrais	Comprimento de onda (nm)	Descrição
01	431 - 452	Coastal Blue
02	465 - 515	Blue
03	513 - 549	Green I
04	547 - 583	Green
05	600 - 620	Yellow
06	650 - 680	Red
07	697 - 713	Red-Edge
08	845 - 885	NIR

Tabela 02. Bandas espectrais - PlanetScope.

Vale destacar que as imagens PlanetScope estão acessíveis no âmbito do Programa Meio Ambiente Integrado e Seguro, estabelecido pelo Ministério da Justiça e Segurança Pública em 2020 (MJSP, 2020). Atualmente, o programa oferece acesso aos produtos de sensoriamento remoto para mais de duzentas instituições por meio de uma plataforma web⁴ (REDE MAIS, 2023).

A constelação Sentinel-2, desenvolvida pela Agência Espacial Europeia (ESA) como parte do programa de observação da Terra Copernicus, foi lançada em junho de 2015 e consiste em dois satélites gêmeos que compartilham a mesma órbita polar, estando posicionados a 180° um do outro e operando a uma altitude média de 786 km (ESA, 2023).

Equipado com o sensor Multispectral Instrument (MSI), esse sistema proporciona produtos ortorretificados com um total de 13 bandas espectrais, oferecendo uma resolução espacial que varia de acordo com a faixa espectral, situando-se entre dez, vinte e sessenta metros. A imagem multiespectral do satélite Sentinel-2 possui uma largura de faixa de 290 km. As imagens utilizadas, processadas no nível 2A, são ortorretificadas e possuem reflectância calculada para o nível da superfície (ibid.).

⁴ <https://plataforma-pf.scon.com.br/#/>

Oliveira & Silva (2021) em uma análise com ortomosaico do IBGE com resolução espacial de 1 m, concluiu que as imagens Sentinel-2 MSI obtidas diretamente da ESA podem ser classificadas com acurácia posicional planimétrica na classe A do Padrão de Exatidão Cartográfica para Produtos Cartográficos Digitais (PEC-PCD) na escala 1:50.000, conforme estabelecido pelo Decreto Federal nº 89.817/1984. Em uma abordagem similar, Immitzer et al. (2016), ao comparar as imagens Sentinel-2 MSI com ortofotos de 20 cm de resolução, também consideraram a acurácia posicional dessas imagens orbitais como muito boa. Por sua vez, Pessanha & Antunes (2019), utilizando pontos coletados em campo com receptores Global Navigation Satellite System (GNSS), concluíram que as imagens Sentinel-2 MSI atendem aos requisitos da Classe A do PEC-PCD para a escala 1:25.000. Optamos por utilizar neste trabalho, exclusivamente, as bandas espectrais originalmente com dez e vinte metros de resolução, conforme detalhado na Tabela 03.

Banda Espectral	Comprimento de onda (nm)	Resolução Espacial (m)	Descrição
02	492,1 – 496,6	10	Blue
03	559 - 560	10	Green
04	664,5 - 665	10	Red
05	703,8 – 703,9	20	Red-Edge
06	739,1 – 740,2	20	Red-Edge 2
07	779,7 – 782,5	20	Red-Edge 3
08	833 – 835,1	10	NIR
8A	864 – 864,8	20	Red-Edge 4
11	1.610,4 – 1.613,7	20	SWIR 1
12	2.185,7 – 2.202,4	20	SWIR 2

Tabela 03. Bandas espectrais utilizadas - Sentinel-2 MSI.

O Programa Cbers (Satélite Sino-Brasileiro de Recursos Terrestres), resultado de uma parceria estatal entre Brasil e China no campo científico espacial, representou um marco importante ao conferir ao Brasil o status de um dos países capazes de gerar dados primários de sensoriamento remoto. A divisão de responsabilidades no programa é equitativa, com cada país contribuindo com 50% (INPE, 2018).

Duas décadas após o lançamento do primeiro satélite dessa parceria, em dezembro de 2019, o satélite Cbers 4A foi lançado ao espaço, com uma altitude média de 628 km e equipado com três câmeras, incluindo a Câmera Multiespectral e Pancromática de Ampla Varredura (WPM). A largura com cada faixa imageada com este sensor é de 92 km. Essa câmera ostenta a mais alta resolução espacial já alcançada pelo programa, com dois metros na banda pancromática (Tabela 04).

Bandas Espectrais	Comprimento de onda (nm)	Resolução Espacial (m)	Descrição
00	450 – 900	02	Pan
01	450 - 520	08	Blue
02	520 - 590	08	Green
03	630 - 690	08	Red
04	770 - 890	08	NIR

Tabela 04. Bandas espectrais - Cbers 4A WPM.

Este trabalho faz uso das imagens Cbers 4A WPM com o nível de processamento L4, escolhidas por sua ortorretificação, correção radiométrica e geometria refinada através de pontos de controle e de um modelo numérico de terreno (INPE, 2021).

De Souza et al. (2023) comparou imagens PlanetScope e Cbers 4A WPM fusionadas com um mosaico de ortofotos de 10 cm de resolução. Verificou-se que a acurácia posicional de ambos os sensores ópticos é semelhante, com erro inferior a 10 m. Além disso, constatou-se que os produtos gerados por esses dois tipos de sensores ópticos orbitais atendem aos requisitos da classe B do Padrão de Exatidão Cartográfica para Produtos Cartográficos Digitais (PEC-PCD).

De acordo com Meireles (2021), a utilização de dados Cbers 4A WPM com este nível de processamento elimina a necessidade de técnicas de pré-processamento, uma vez que essas imagens já passaram por correções radiométricas e geométricas realizadas por profissionais do INPE. Dessa forma, os efeitos ambíguos de perspectivas e a influência do relevo sobre a geometria da imagem são previamente reduzidos.

Entre os sensores utilizados na pesquisa, apenas o CBERS 4A WPM não foi disponibilizado com valores de reflectância, e não identificamos na literatura os parâmetros necessários para a transformação de números digitais em reflectância. Veras (2022) também mencionou a ausência desses parâmetros de calibração, no entanto, o autor observou que realizar o processamento com os números digitais brutos da imagem e sem correção atmosférica não impediu a geração de índices de vegetação com valores próximos aos obtidos pelas imagens dos satélites Landsat 08 e Sentinel-2 MSI, os quais já possuíam valores de reflectância.

O SFB disponibilizou os dados Lidar aerotransportados que foram utilizados na validação das classificações realizadas com imagens ópticas. Esses dados foram coletados em uma parcela da área de trabalho abrangendo quinhentos hectares, equivalente a 16,8% da área da UPA 4D, conforme ilustrado na Figura 01.

De acordo com Locks (2017), em aplicações voltadas para florestas densas, como as encontradas nas florestas tropicais do Brasil, é essencial prestar a atenção à densidade de pulsos dos dados Lidar. Um estudo conduzido na Floresta Atlântica brasileira por Leitold et al. (2015) constatou que modelos tridimensionais gerados a partir de dados com uma densidade de vinte pulsos por metro quadrado apresentaram alta precisão. Por outro lado, conjuntos de dados com densidades reduzidas, com menos de oito pulsos por metro quadrado, tornaram-se progressivamente menos precisos, levando à subestimação da altura das árvores devido à incapacidade de modelar adequadamente a superfície do terreno.

A densidade de 25 pulsos por metro quadrado utilizada por D'Oliveira et al. (2012) em estudo conduzido na Floresta Estadual de Antimary, no estado do Acre, proporcionou um nível extremamente detalhado de informações. Além disso, em uma pesquisa realizada por Dalagnol et al. (2019) em concessão florestal na Flona do Jamari, os autores foram ainda mais longe ao considerar densidades acima de 12 pulsos por metro quadrado e, portanto, adequadas para a obtenção de métricas florestais.

A coleta dos dados utilizados Lidar utilizados nesta pesquisa ocorreu em 22/05/2021, por meio do sensor OPTECH/GEMINI/09SEN246, a uma altitude média de setecentos metros acima do solo e uma densidade média de 29,59 pulsos por metro quadrado. Os dados Lidar, em formato de nuvem de pontos, foram disponibilizados por meio de 14 faixas de mapeamento. A Figura 06 apresenta uma destas faixas.

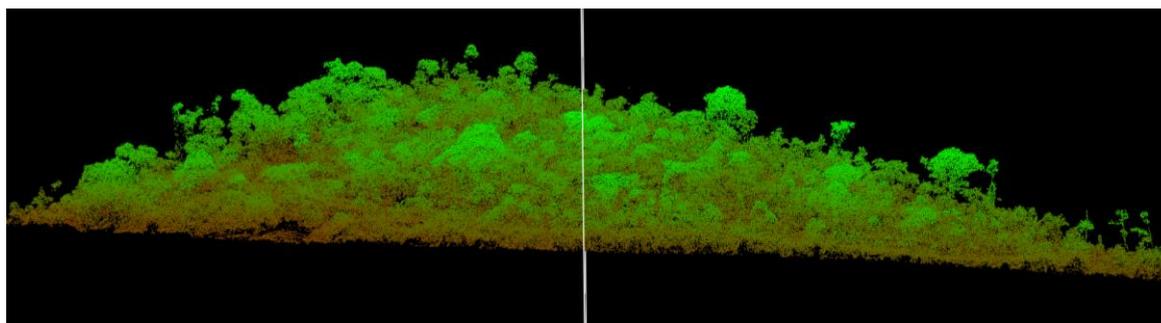


Figura 06. Nuvem de pontos em uma das faixas de mapeamento com Lidar.

A definição de clareira utilizada foi proposta por Brokaw (1982), que as define como áreas abertas dentro de uma floresta que se estendem verticalmente até uma altura média de cerca de dois metros acima do solo, com tamanhos mínimos variando entre 20 m² e 40 m². Classificamos as clareiras oriundas do MFS em dois grupos: clareira de exploração, resultantes do impacto da copa das árvores abatidas sobre a vegetação circundante, e clareiras de infraestrutura, que incluem estradas e pátios de estocagem instalados para viabilizar operacionalmente a exploração florestal.

As clareiras associadas à infraestrutura geralmente exibem solo exposto devido às atividades de corte de toras, carregamento e transporte. Durante a safra madeireira, o constante tráfego de veículos e tratores impede o processo de regeneração dessas áreas. Essa exposição do solo, combinada ao maior dimensionamento, proporciona uma notável diferenciação espectral e espacial em relação ao dossel florestal, tornando essas estruturas mais facilmente distinguíveis aos sensores ópticos. Em contraste, as clareiras de exploração apresentam-se total ou parcialmente cobertas por resíduos provenientes da copa das árvores abatidas e da vegetação circundante impactada, além de não estarem sistematicamente distribuídas e apresentarem formatos irregulares, dificultando, tanto a diferenciação espacial, quanto espectral em relação ao dossel florestal (READ, 2003; READ et al., 2003; ASNER et al., 2004, 2005; MATRICARDI et al., 2005; MONTEIRO, 2005; SOUZA Jr et al., 2005; SILVA, 2014; MASILIŪNAS, 2017; HERNANDEZ-GOMEZ et al., 2019; HETHCOAT et al., 2019; LIMA et al., 2019; DALAGNOL et al., 2023; WELSINK et al., 2023).

Considerando que os dados de localização da infraestrutura na UPA 4D são realizados com confirmação em campo pela concessionária, estes dados foram utilizados como referência para avaliar a correspondência posicional entre os processamentos realizados. E também, serviram de referência para a coleta das amostras de treinamento e validação, bem como para avaliação dos ajustes nos parâmetros de segmentação e de classificação.

Observamos que, em relação à disposição dos pátios de estocagem e estradas, as imagens de satélite demonstraram uma acurácia posicional, tanto em comparação entre si quanto com o Modelo Digital de Superfície (MDS) gerado a partir dos dados Lidar. Desta forma, não foram implementadas correções geométricas às imagens utilizadas, assim como não foram empregados procedimentos adicionais de correção atmosférica, além dos já realizados pelos fornecedores das imagens PlanetScope e Sentinel-2 MSI.

Neste estudo, optamos pela classificação supervisionada, na qual as classes são definidas a priori. Para processar as imagens de sensoriamento remoto, empregamos duas abordagens distintas: a Classificação Pixel a Pixel e a Análise de Imagem Baseada em Objetos Geográficos (Geobia). Segundo Menezes & Almeida (2012), o processamento digital de imagens refere-se à execução de operações matemáticas com o objetivo de aprimorar as qualidades espectrais e espaciais das imagens para aplicações específicas.

Para avaliar o comportamento dos sensores ópticos sob diversas técnicas e composições de dados, adotamos diversas combinações de bandas espectrais e processamentos, incluindo segmentação, cálculo do NDVI, fusão espectral, reamostragem de

resolução espacial, além das técnicas de mapeamento Pixel a Pixel e Geobia. Isso resultou em 14 conjuntos de dados distintos, os quais foram submetidos à classificação por meio de algoritmos baseados em aprendizado de máquina: K-Nearest Neighbors (K-NN), Random Forest (RF) e Support Vector Machine (SVM). Assim, foram realizados um total de 42 mapeamentos das clareiras florestais na UPA 4D.

Com o intuito de simplificar a apresentação dos resultados desta pesquisa, empregamos a expressão “Técnicas de mapeamento”, para nos referirmos especificamente aos métodos de classificação de imagens Pixel a Pixel e Geobia. Além disso, utilizamos a expressão “Conjunto de dados” para nos referirmos à cada conjunto de camadas de dados espaciais que foram empilhadas e convertidas em um só arquivo e, que, em alguns casos, foram submetidos ao processo de segmentação (Figuras 07 a 09).

Realizamos o procedimento de fusão de imagens com os dados Cbers 4A WPM, o que possibilitou a combinação das informações espaciais com dois metros de resolução provenientes da banda pancromática, juntamente com o maior detalhamento espectral proporcionado pelas quatro bandas multiespectrais com oito metros de resolução. A fusão foi executada pelo método cúbico, utilizando a ferramenta Pansharpening disponível no complemento Gdal no Qgis. Para avaliarmos o efeito da fusão dos dados Cbers 4A WPM no mapeamento das clareiras florestais, foram gerados conjuntos de dados com as duas resoluções espaciais; entretanto, apenas os dados com maior resolução espacial foram submetidos à segmentação.

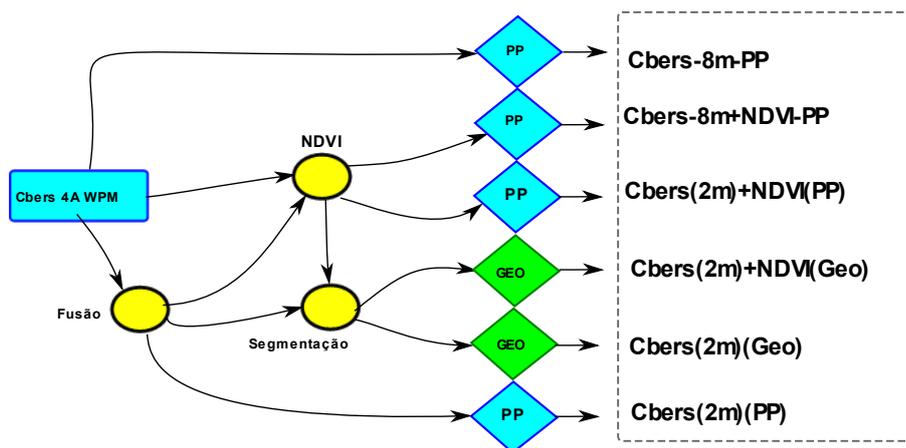


Figura 07. Composição dos conjuntos de dados com imagens Cbers 4A WPM

Da mesma forma, os dados Sentinel-2 MSI também não foram submetidos ao processo de segmentação. Essa escolha baseia-se na exposição apresentada no Capítulo 04, que destaca que a técnica Geobia é mais apropriada quando são utilizadas resoluções espaciais nas quais as áreas representadas por cada pixel são significativamente menores em relação aos objetos

que necessitam de mapeamento. Contudo, para as resoluções espaciais de dez metros (Sentinel-2 MSI) e oito metros (Cbers 4A WMP), acreditamos que as áreas representadas por cada pixel estejam em uma ordem de grandeza semelhante às dimensões das clareiras presentes nas áreas em estudo. Desta forma, os mapeamentos por Geobia se restringiram aos dados Cbers 4A WPM fusionados e PlanetScope, enquanto a técnica Pixel a Pixel foi utilizada em todos os sensores ópticos e resoluções espaciais adotadas.

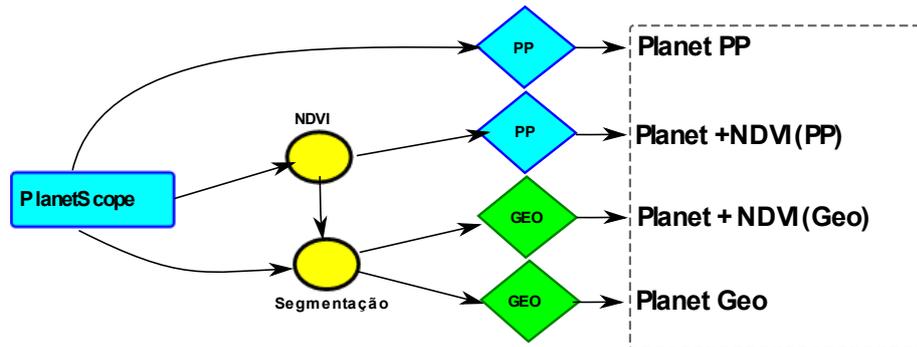


Figura 08. Composição dos conjuntos de dados com imagens PlanetScope

Considerando a escolha que fizemos de utilizar as maiores resoluções espaciais disponíveis, dada a importância desta característica no mapeamento de ESM, conforme detalhado no Capítulo 03, optamos por não utilizar as bandas com sessenta metros de resolução espacial do sensor Sentinel-2 MSI, restando, portanto, dez bandas espectrais, sendo, quatro com resolução de dez metros e seis com resolução de vinte metros. Para permitir uma análise integrada com dados originalmente em diferentes resoluções espaciais, reamostramos as bandas espectrais de vinte metros para dez metros utilizando o método bilinear, por meio da ferramenta "r.resample" disponível no complemento Grass do Qgis. Testamos os classificadores tanto em conjunto de dados composto com as quatro bandas espectrais nativas em maior resolução, como com as dez bandas espectrais, valendo-se, neste caso, de um maior detalhamento espectral.

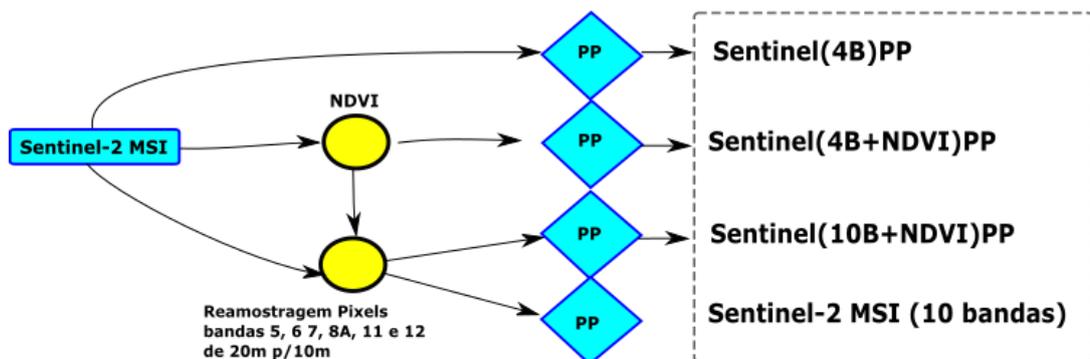


Figura 09. Composição dos conjuntos de dados com imagens Sentinel-2 MSI

Calculamos o NDVI $\left(\frac{\text{Nir} + \text{Red}}{\text{Nir} - \text{Red}}\right)$ (01) nas imagens de todos os sensores ópticos e resoluções espaciais adotadas, a fim de avaliarmos sua contribuição ao processo de mapeamento das clareiras florestais. Tanajura et al. (2005) e Ghimire et al. (2020) destacam que, mesmo com o processo de fusão de imagens, que poderia potencialmente afetar a qualidade dos índices de vegetação, estes permanecem com boa qualidade. Isso é especialmente evidente quando a relação entre as resoluções espaciais da banda pancromática e multiespectral é pequena, como ocorre nos dados Cbers 4A WPM, em que a relação é de 1:4. A Tabela 05 detalha a composição de cada conjunto de dados classificado.

	Sensor	Resolução Espacial	Bandas Espectrais	NDVI	Técnica	Nome do Conjunto de dados
01	Cbers 4A WPM	08 m	01 a 04	Não	Pixel a Pixel	Cbers-8m-multi-PP
02				Sim		Cbers-8m-multi+NDVI-PP
03		02 m	01 a 04 (Pan)	Não	Pixel a Pixel	Cbers(2m)multi(PP)
04					Geobia	Cbers(2m)multi(Geo)
05				Sim	Pixel a Pixel	Cbers(2m)multi+NDVI(PP)
06					Geobia	Cbers(2m)multi+NDVI(Geo)
07	PlanetScope PSB.SD	03 m	01 a 08	Não	Pixel a Pixel	Planet(multi)PP
08					Geobia	Planet(multi)Geo
09				Sim	Pixel a Pixel	Planet(multi+NDVI)PP
10					Geobia	Planet(multi+NDVI)Geo
11	Sentinel-2 MSI	10 m	02 a 04 e 08	Não	Pixel a Pixel	Sentinel(4B)PP
12				Sim		Sentinel(4B+NDVI)PP
13			02 a 08, 8A, 11 e 12	Não		Sentinel(10B)PP
14				Sim		Sentinel(10B+NDVI)PP

Tabela 05. Conjuntos de dados com os sensores ópticos classificados

6.1 PARAMETRIZAÇÃO DO ALGORITMO DE SEGMENTAÇÃO

As segmentações foram realizadas com o uso do algoritmo LSMS (MICHEL et al., 2015), disponível no complemento OTB no Qgis. O algoritmo LSMS, por padrão, calcula as seguintes métricas: quantidade de pixels, média e variância, as quais são incorporadas à tabela de atributos. Com o intuito de ampliar o conjunto de recursos disponíveis e, potencialmente, aprimorar a precisão da classificação, foram calculados, adicionalmente, por meio da ferramenta "Zonal Statistics", também disponível no OTB, o desvio padrão, os valores mínimos e máximos para cada segmento. Esses cálculos são efetuados com base nos valores dos pixels de cada camada que compõe os conjuntos de dados classificados por Geobia.

A falta de referências adequadas na literatura, das quais poderíamos extrair sugestões para a seleção dos valores dos parâmetros, teve um impacto significativo em nossa abordagem. Conduzimos uma pesquisa nas plataformas online Web of Science e Google Scholar, entretanto, não identificamos estudos que tenham empregado o algoritmo de segmentação LSMS com imagens Cbers 4A WPM e PlanetScope que pudessem ser utilizados como referência para a realização dos ajustes paramétricos.

Conforme abordado no Capítulo 04, existem três parâmetros que precisam ser ajustados para realizar a segmentação de imagens com o algoritmo LSMS: Raio da Vizinhança Espacial (RVE), Raio de Alcance Espectral (RAE) e Tamanho Mínimo do Segmento (TMS). A definição dos valores considerados ótimos para os parâmetros do LSMS foi alcançada por meio de um processo de tentativa e erro, uma abordagem comumente empregada neste algoritmo (IMMITZER et al., 2016; MASCHLER et al., 2018; DE LUCA et al., 2019; DUARTE et al., 2020; BOZKURT, 2021; MODICA et al., 2021; STOLL et al., 2021; KILLEEN et al., 2022).

Os valores dos parâmetros RVE e RAE estão inversamente relacionados à quantidade de segmentos. Quanto maiores forem esses valores, menor será a quantidade de segmentos criados. Valores elevados de RVE e RAE promovem uma maior suavização e uma menor preservação das bordas, podendo, em casos extremos, levar à subsegmentação. Em contrapartida, valores mais baixos de RVE e RAE resultam em uma maior quantidade de segmentos e uma maior preservação das bordas, podendo, em situações extremas, levar à supersegmentação (DE LUCA et al., 2019; BOZKURT, 2021; ORFEO, 2023).

No que diz respeito ao TMS, optamos por não adotar o valor padrão (50) proposto pelo software. Em vez disso, determinamos o valor para esse parâmetro com base na resolução espacial das imagens utilizadas, levando em consideração a definição de clareiras florestais

conforme proposta por Brokaw (1982). Estabelecemos o tamanho mínimo para os segmentos em 10 pixels (40m²) para os dados fusionados do sensor Cbers 4A WPM e em 5 pixels (45m²) para os dados PlanetScope. O objetivo foi garantir que os tamanhos mínimos dos segmentos estivessem em consonância com a definição de clareiras florestais proposta por Brokaw (1982).

Diante do exposto, conduzimos uma série de testes por meio do processo de tentativa e erro, explorando diversas combinações de valores para os parâmetros RVE e RVA. Utilizamos como ponto de partida os valores padrão previstos no OTB, respectivamente 05 e 15. No entanto, após a interpretação visual, utilizando as clareiras de infraestrutura como referência e com o objetivo de priorizar uma preservação mais robusta das bordas e dada a complexidade da paisagem mapeada, decidimos utilizar o valor 01 tanto para RVE como para RVA. A estratégia de utilizar valores menores de distância espacial e espectral para segmentar imagens orbitais com o algoritmo LSMS foi utilizada por Immitzer et al. (2016) ao mapear áreas de alta heterogeneidade florestal na Europa Central.

É notável que o parâmetro TMS desempenha um papel significativo nos resultados da segmentação utilizando o algoritmo LSMS. Isso fica evidente, pois, ao manter esse valor constante e ajustar os outros dois parâmetros, os resultados exibiam uma quantidade de segmentos bastante semelhante. Entretanto, qualquer aumento ou redução nos valores de TMS provocava alterações substanciais na quantidade de segmentos gerados. A Tabela 06 apresenta a parametrização adotada para o algoritmo LSMS e alguns dados estatísticos dos resultados obtidos com cada conjunto de dados segmentado. As Figuras 10 e 11 exibem a segmentação realizada utilizando os parâmetros padrão do algoritmo LSMS no OTB, correspondendo, respectivamente, às imagens Cbers 4A WPM e PlanetScope, ambas sem a incorporação do NDVI. Já as Figuras 12 e 13 representam a segmentação aplicando as parametrizações adotadas neste estudo.

Conjunto de dados	RVE	RVA	TMS	Nº de Segmentos	Média (m ²)	Mediana (m ²)	Moda (m ²)	DP (m ²)
Cbers(2m)multi	1	1	10	411.093	72,37	64	40	28
Cbers(2m)multi+NDVI	1	1	10	417.517	71,28	64	40	28
Planet(multi)	1	1	05	369.055	80,73	72	54	33,39
Planet(multi+NDVI)	1	1	05	369.058	80,82	72	54	33,39

Tabela 06. Parametrização adotada e estatísticas dos resultados da segmentação.

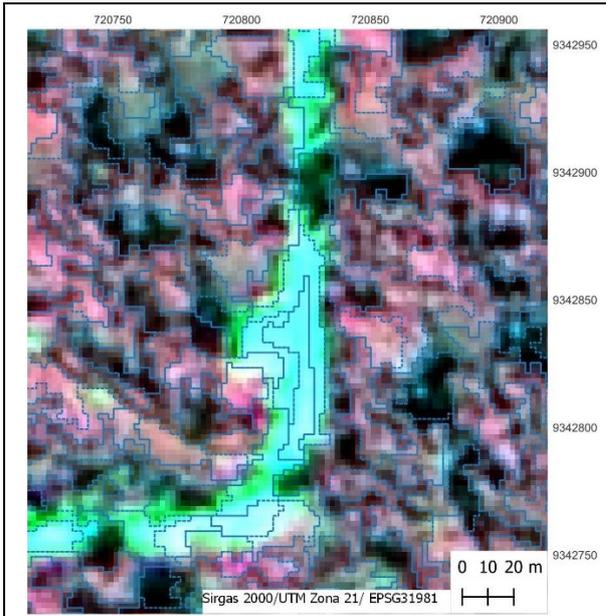


Figura 10. Segmentação de imagem Cbers 4A WPM fusionada, composição 432. Parametrização LSMS: RVE (05) RVA (15) TMS (50).

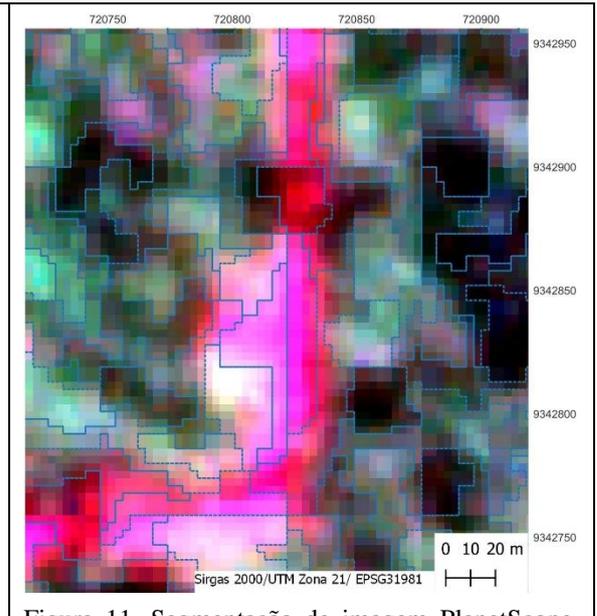


Figura 11. Segmentação de imagem PlanetScope, composição 687. Parametrização LSMS: RVE (05) RVA (15) TMS (50).

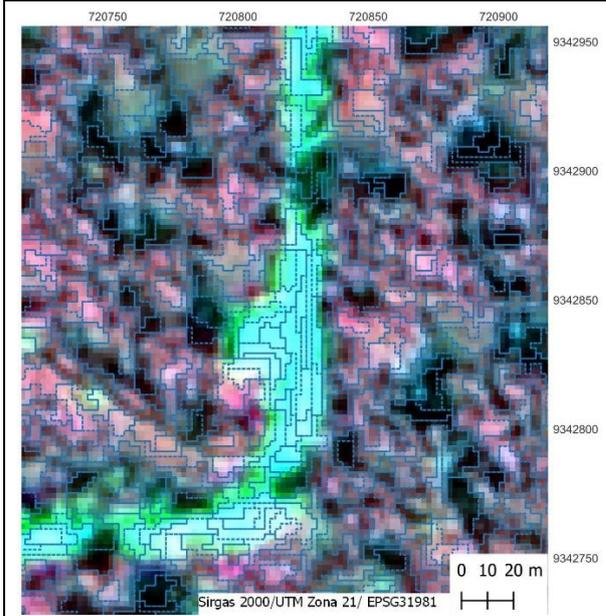


Figura 12. Segmentação de imagem Cbers 4A WPM fusionada, composição 432. Parametrização LSMS: RVE (01) RVA (01) TMS (10).

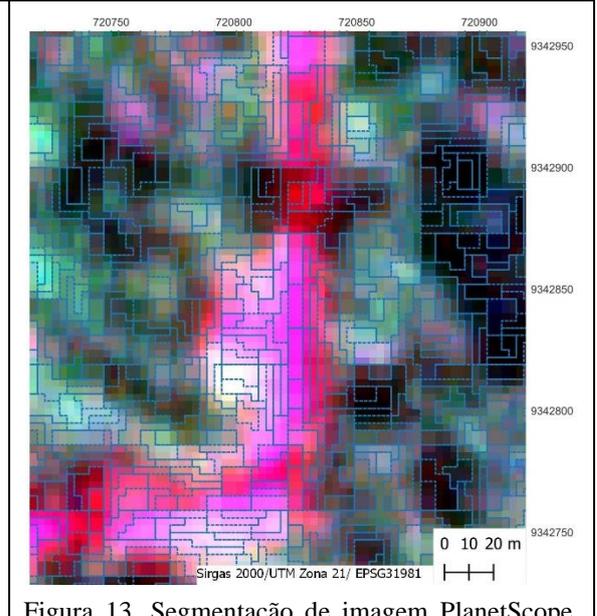


Figura 13. Segmentação de imagem PlanetScope, composição 687. Parametrização LSMS: RVE (01) RVA (01) TMS (05).

6.2 SELEÇÃO DAS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO INTERNA

De acordo com Maxwell et al. (2018), o tamanho, a qualidade e o balanceamento das amostras por classe de treinamento podem ser elementos mais relevantes para a precisão da classificação do que a escolha do algoritmo em si, e devem ser tratados como prioridade no planejamento do processo de mapeamento. Para Meireles (2021), a utilização de bases de treinamento com uma quantidade insuficiente de amostras pode resultar em um processo de classificação confuso, tornando desafiadora a diferenciação entre as classes. Por outro lado, o acréscimo excessivo de amostras de treinamento pode tornar o processo de aprendizado excessivamente complexo.

A coleta de amostras foi realizada por meio de interpretação visual, levando em consideração os elementos chaves para fotointerpretação, como padrão, cor, tonalidade, tamanho, textura, forma e sombra, conforme descrito por Soares Filho (2020).

Embora o objetivo da pesquisa seja mapear exclusivamente as clareiras florestais, os classificadores foram treinados para distinguir duas classes: clareiras e dossel florestal. Os pixels representados por sombras, que se tornam mais significativos à medida que a resolução espacial aumenta, foram agrupados na classe referente ao dossel florestal.

Dada a complexidade em identificar com segurança as clareiras florestais nos dados orbitais utilizados, a fim de evitar equívocos durante a coleta das amostras, priorizamos pixels que exibiam uma distinção visual mais evidente entre as classes mapeadas. Para alcançar esse objetivo, as amostras da classe "clareiras" foram coletadas prioritariamente em áreas sobrepostas à infraestrutura instalada, conforme dados fornecidos pela empresa concessionária. Já para a classe "dossel florestal", demos preferência aos pixels que apresentavam valores mais elevados de NDVI.

Realizamos a vetorização manual diretamente sobre os pixels das imagens para gerar as amostras necessárias nas classificações a serem conduzidas pelo método Pixel a Pixel. Na coleta de amostras para a aplicação das classificações utilizando Geobia, selecionamos os segmentos em formato vetorial que interseccionavam ou estavam sobrepostos às amostras coletadas diretamente sobre os pixels. Posteriormente, por meio de uma análise visual, excluimos os segmentos que não atendiam aos nossos critérios interpretativos. Para ampliar a distribuição espacial, foram coletadas amostras de ambas as classes em todas as 26 Unidades de Trabalho, que são subdivisões operacionais da UPAs. Importante ser destacado que buscamos mapear as clareiras independentemente se são originadas em função do manejo da

vegetação ou de processos naturais. Segundo Hunter et al. (2015) e Locks (2017), uma boa parte delas ocorre naturalmente.

Para possibilitar estimar internamente a taxa de predição correta nas classificações, as amostras foram divididas em dois conjuntos, treinamento e teste. O primeiro é utilizado no aprendizado do algoritmo para geração do modelo de classificação, enquanto o segundo tem a função de medir o grau de efetividade da predição da classe dos novos dados. Essa técnica é conhecida como Out-of-bag (OOB). Breiman (2001) afirma que a estimativa OOB é imparcial e sugere a alocação de dois terços das amostras para o treinamento dos classificadores e um terço para a validação, e foi dessa maneira que nós procedemos. Conforme apontado por Hethcoat et al. (2019), a fim de aumentar a independência da avaliação, não incluímos amostras repetidas nos dois grupos.

No contexto da área amostral, optamos por selecionar amostras de ambas as classes mapeadas, abrangendo uma faixa entre 0,35% e 0,4% da extensão total da UPA 4D (2.975ha). Assim, atendemos à recomendação de Than Noi & Capas (2018), que sugere que, em classificações de uso da terra utilizando imagens de sensoriamento remoto e algoritmos de aprendizado de máquina, o tamanho da amostra de treinamento deve representar aproximadamente 0,25% da área total do estudo.

Nas classificações realizadas através da técnica Pixel a Pixel, as mesmas amostras foram aplicadas aos conjuntos de dados provenientes do mesmo sensor e com a mesma resolução espacial, conforme indicado na Tabela 07.

Conjunto de dados	Amostras Clareira	Pixels Clareira	Área Clareira (ha)	Amostras Dossel	Pixels Dossel	Área Dossel (ha)
Cbers-8m-multi(PP)	332	1.632	10,44	141	1.656	10,6
Cbers-8m-multi+NDVI(PP)						
Cbers-2m-multi(PP)	344	26.640	10,65	301	26.657	10,66
Cbers-2m-multi+NDVI(PP)						
Planet-multi(PP)	263	11.758	10,58	128	11.595	10,43
Planet-multi+NDVI(PP)						
Sentinel-10B(PP)	155	1.052	10,52	71	1.047	10,47
Sentinel-10B+NDVI(PP)						
Sentinel-4B-(PP)						
Sentinel(4B+NDVI)						

Tabela 07. Quantitativo de amostras utilizadas para classificação e validação de cada conjunto de dados com o uso da técnica pixel a pixel.

Por outro lado, nas classificações por Geobia, como os segmentos são formados com base em estatísticas calculadas a partir de cada dado empilhado que compõe o conjunto. Isso resulta em segmentações distintas, mesmo quando os dados têm origem no mesmo sensor e

possuem a mesma resolução espacial. Portanto, as amostras empregadas são específicas para cada conjunto de dados classificado por Geobia, conforme apresentado na Tabela 08.

Conjunto de dados	Segmentos Clareira	Área Clareira (ha)	Segmentos Dossel	Área Dossel (ha)
Cbers-2m-multi(Geo)	1.963	10,58	1.786	10,55
Cbers-2m-multi+NDVI(Geo)	1.386	10,6	1.419	10,37
Planet-multi(Geo)	1.279	10,6	1.262	10,56
Planet-multi+NDVI(Geo)	1.264	10,64	1.275	10,45

Tabela 08. Quantitativo de amostras utilizadas para classificação e validação de cada conjunto de dados com o uso da técnica Geobia.

As Figuras 14 a 19 apresentam exemplos de amostras coletadas para as duas classes mapeadas, utilizando cada tipo de sensor, resolução espacial e técnica de mapeamento adotada, seja Geobia ou Pixel a Pixel.

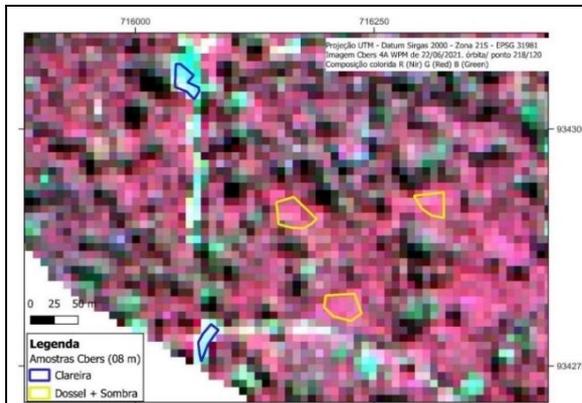


Figura 14. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Cbers 4A WPM com oito metros de resolução espacial.

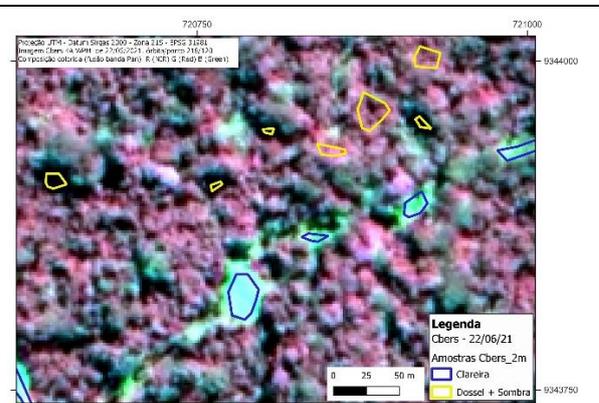


Figura 15. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Cbers 4A WPM com dois metros de resolução espacial.

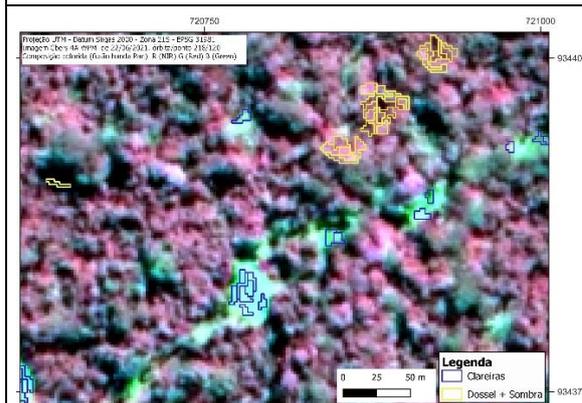


Figura 16. Exemplo de amostras coletadas para classificação por Geobia em imagem Cbers 4A WPM com dois metros de resolução espacial.

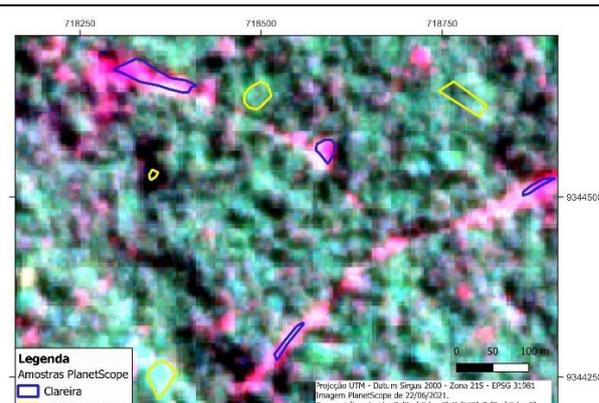


Figura 17. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem PlanetScope.

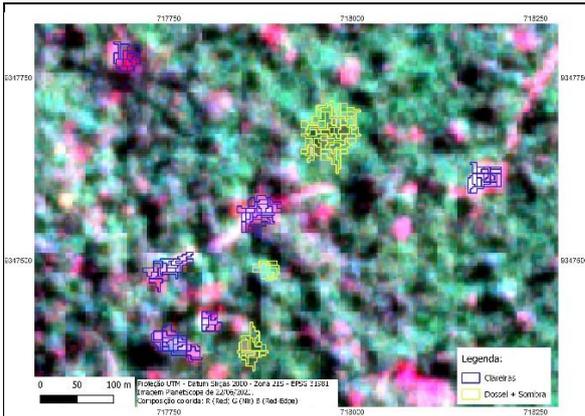


Figura 18. Exemplo de amostras coletadas para classificação por Geobia em imagem PlanetScope.

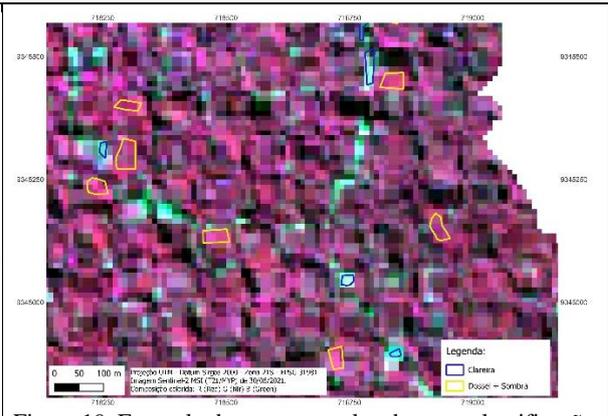


Figura 19. Exemplo de amostras coletadas para classificação Pixel a Pixel em imagem Sentinel-2 MSI.

Utilizando os dados Cbers 4A WPM e Sentinel-2 MSI, a composição colorida RGB que proporcionou a melhor diferenciação visual das clareiras foi a seguinte: 4 (NIR) 3 (vermelho) 2 (verde), na qual as clareiras são representadas em ciano e o dossel florestal em magenta. No que diz respeito aos dados do PlanetScope, optamos pela composição das bandas RGB 8 (NIR), 4 (vermelho) e 7 (Red Edge 3), neste caso, as clareiras são representadas em magenta, enquanto o dossel é exibido em ciano. As Figura 20 a 24 apresentam exemplos da assinatura espectral de amostras coletadas com cada tipo de sensor, resolução espacial e quantidade de bandas espectrais adotada.

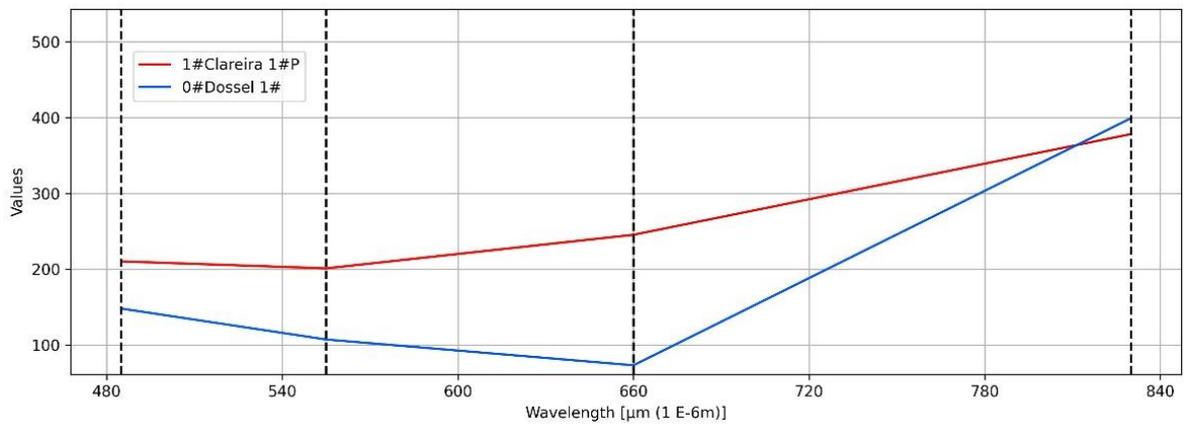


Figura 20. Exemplo de assinatura espectral média de amostras coletadas com dados Cbers 4A WPM em resolução espacial de oito metros. As linhas pontilhadas representam o comprimento médio das bandas espectrais, em ordem crescente: Azul, Verde, Vermelho e Infravermelho Próximo. Valores dos pixels em números digitais.

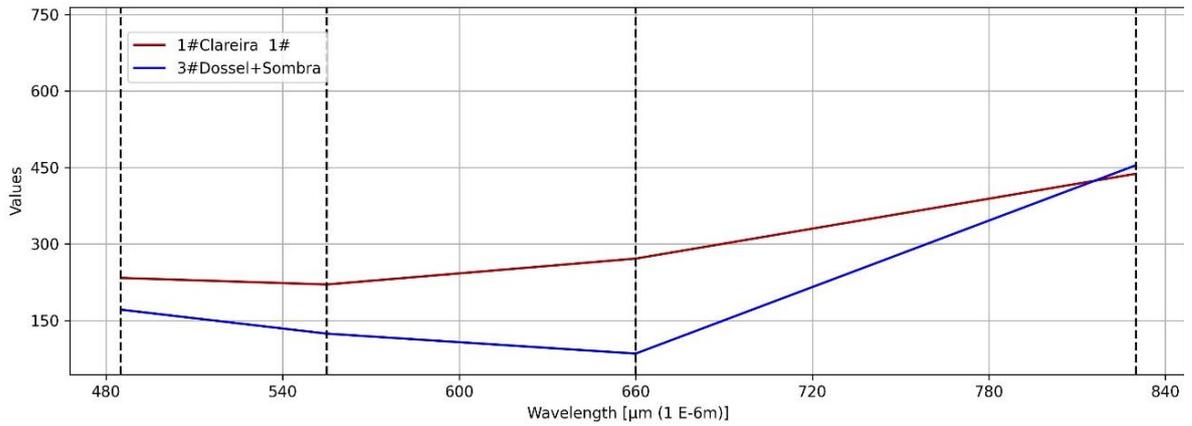


Figura 21. Exemplo de assinatura espectral média de amostras coletadas com dados Cbers 4A WPM em resolução espacial de dois metros. As linhas pontilhadas representam o centro do comprimento das bandas espectrais, em ordem crescente: Azul, Verde, Vermelho e Infravermelho próximo. Valores de reflectância dos pixels.

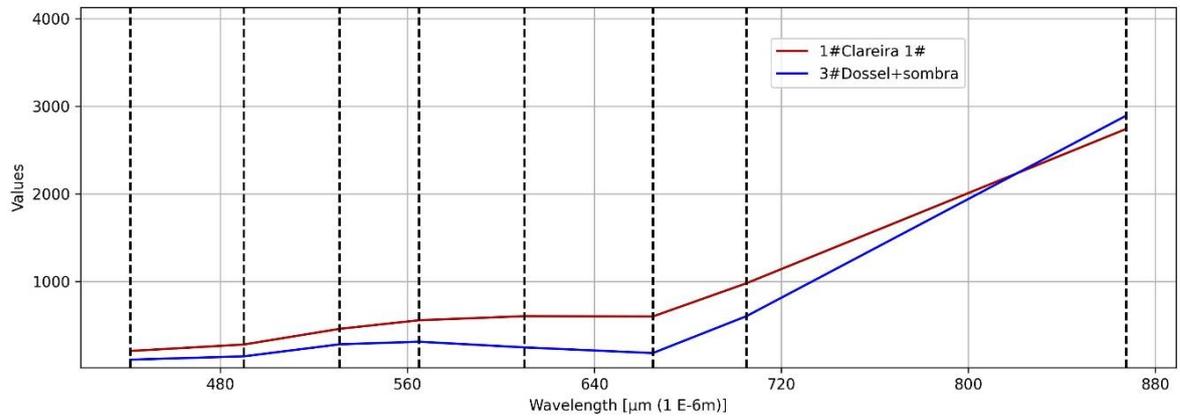


Figura 22. Exemplo de assinatura espectral média de amostras coletadas com dados PlanetScope. As linhas pontilhadas representam o comprimento médio das bandas espectrais, em ordem crescente: Azul Costal, Azul, Verde I, Verde, Amarelo, Vermelho, Borda do Vermelho e Infravermelho próximo. Pixels com valores de reflectância.

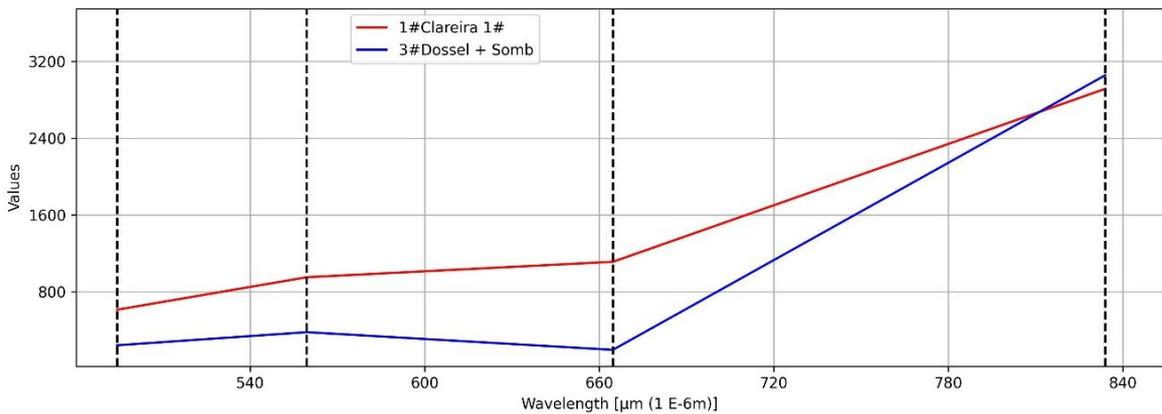


Figura 23. Exemplo de assinatura espectral média de amostras coletadas com dados Sentinel-2 MSI com quatro bandas espectrais. As linhas pontilhadas representam o comprimento médio das bandas espectrais, em ordem crescente: Azul Costal, Azul, Verde I, Verde, Amarelo, Vermelho, Borda do Vermelho e Infravermelho próximo. Pixels com valores de reflectância.

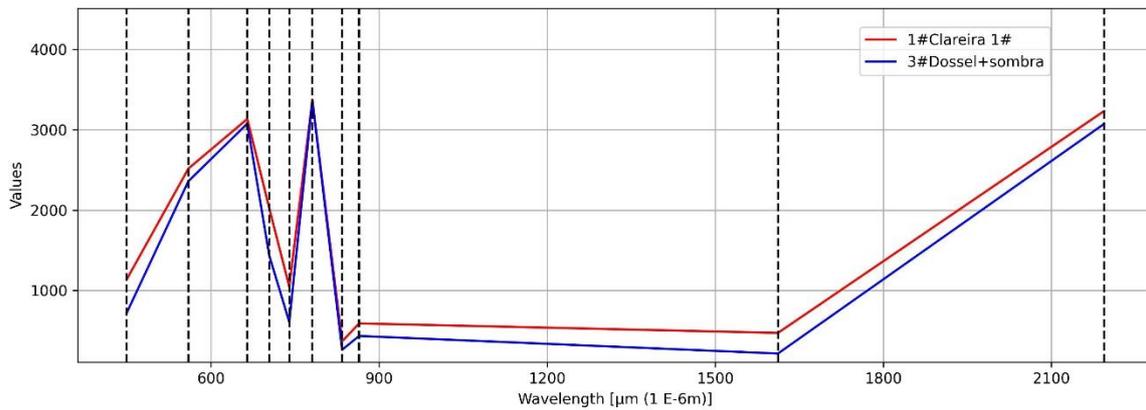


Figura 24. Exemplo de assinatura espectral média de amostras coletadas com dados Sentinel-2 MSI com dez bandas espectrais. As linhas pontilhadas representam o comprimento médio das bandas espectrais, em ordem crescente: Azul Costal, Azul, Verde I, Verde, Amarelo, Vermelho, Borda do Vermelho e Infravermelho próximo. Pixels com valores de reflectância.

6.3 PARAMETRIZAÇÃO DOS ALGORITMOS DE CLASSIFICAÇÃO

Conforme delineado por Lawrence & Moran (2015), a classificação de dados de sensoriamento remoto demanda uma abordagem comparativa de diversos métodos, a fim de determinar qual proporciona o melhor desempenho para determinado conjunto de dados e objetivos analíticos em questão. Segundo Maxwell et al. (2018), o classificador ideal e seus parâmetros de ajuste são intrinsecamente específicos a cada caso, pois sua eficácia varia em função das classes mapeadas, do tipo de dados, da qualidade do treinamento e das variáveis preditoras envolvidas.

Dada às poucas referências na literatura que se relacionem à classificação de imagens provenientes dos sensores ópticos que utilizamos no mapeamento de clareiras em áreas sob MFS, enfrentamos desafios na obtenção de orientações para a escolha dos ajustes dos parâmetros necessários aos algoritmos de classificação. Semelhante à experiência na definição dos parâmetros para o algoritmo de segmentação, essa lacuna teve um impacto significativo em nossa abordagem para a parametrização dos algoritmos de classificação.

Diversos estudos, como os conduzidos por Immitzer et al. (2016), De Luca et al. (2019) e Killen et al. (2022), atestam que os valores padrão dos parâmetros de ajuste nos algoritmos de classificação integrados ao OTB proporcionam desempenho otimizado. Esses valores podem ser consultados em Orfeo (2024a) para classificação Pixel a Pixel e em Orfeo (2024b) para classificações realizadas por Geobia. Em consonância com nossa intenção de facilitar a reprodução dos experimentos, optamos por manter os valores padrão para a maioria dos parâmetros dos algoritmos utilizados.

No entanto, através de um processo de tentativa e erro, realizamos ajustes específicos para cada conjunto de dados nos parâmetros mais críticos de cada algoritmo, que abrangem, conforme delineado no Capítulo 04, o número de árvores no RF, o valor de "C" para o Support Vector Machine SVM e o valor de "K" no K-NN. Escolhemos, conforme apresentado na Tabela 09, os valores de ajuste dos parâmetros que contribuíram para alcançar os melhores resultados da métrica F-score para a classe clareira, utilizando o método de validação interna OOB. Processos empíricos de tentativa e erro são amplamente utilizados, conforme aponta a literatura, no ajuste dos parâmetros dos algoritmos de classificação com imagens de sensoriamento remoto (M. PAL, 2005; THAN NOI & CAPAS, 2017; STOLL et al., 2021; ZIEGELMAIER NETO, 2022).

Conjunto de dados	RF (n° árvores)	K-NN (K)	SVM (C)
Cbers-8m-multi(PP)	100	5	100
Cbers-8m-multi+NDVI(PP)	25	1	100
Cbers-2m-multi(PP)	10	5	1
Cbers-2m-multi+NDVI(PP)	100	1	1
Cbers-2m-multi(Geo)	100	1	0,1
Cbers-2m-multi+NDVI(Geo)	100	10	0,1
Planet-multi(PP)	100	10	1
Planet-multi+NDVI(PP)	100	10	1
Planet-multi(Geo)	100	1	1.000
Planet-multi+NDVI(Geo)	100	5	0,1
Sentinel-4B-(PP)	100	10	10
Sentinel(4B+NDVI)	1.000	5	1
Sentinel-10B(PP)	100	1	0,1
Sentinel-10B+NDVI(PP)	100	1	1

Tabela 09. Configuração do principal parâmetro dos algoritmos de classificação em cada conjunto de dados.

Seguimos os seguintes critérios para escolha dos parâmetros dos algoritmos de classificação, quando os resultados para a métrica F-score são semelhantes com diferentes ajustes: para RF, optamos por priorizar valores menores para o número de árvores, com um mínimo de 100, conforme sugerido por Maxwell et al. (2018). Embora Li et al. (2016) recomendem o uso de muitas árvores para diminuir a correlação entre elas e melhorar a capacidade de generalização, Maxwell et al. (2018) destacam que a qualidade da classificação tende a se estabilizar após um certo número de árvores, resultando em um efeito de platô. Observamos este efeito em muitos dos conjuntos de dados utilizados. Ao gerar modelos de classificação com até 10.000 árvores, notamos que os valores de F-score permaneceram constantes na maioria dos casos. As exceções foram nos conjuntos de dados "Cbers-2m-multi(PP)" e "Cbers-8m-multi+NDVI(PP)", onde a escolha de um número menor que 100 árvores resultou em melhores resultados para a métrica F-score. No caso do conjunto de dados "Sentinel(4B+NDVI)", o efeito de platô foi alcançado com 1.000 árvores.

Essa estabilidade do algoritmo RF com conjunto de dados utilizados, de acordo com M.Pal (2005), indica que o RF é insensível ao overfitting, ou seja, é capaz de manter um bom desempenho de generalização, mesmo quando há muitos parâmetros ou quando os dados de treinamento são complexos. Em outras palavras, ele pode evitar ajustar-se demais aos dados de treinamento, mantendo sua capacidade de fazer previsões precisas em dados não vistos. Isso é altamente desejável em aplicações práticas, onde a capacidade de generalização é fundamental para o sucesso do modelo.

Para o parâmetro “K”, nos nossos experimentos, consideramos o valor mínimo de $K=1$. Isso se deve à natureza do algoritmo, que se baseia em critérios de proximidade, avaliando individualmente os pixels (Pixel a Pixel) ou segmentos (Geobia) mais próximos da amostra a ser classificada. Portanto, não exploramos valores fracionários para este parâmetro.

Dado o tamanho reduzido das clareiras florestais, que geralmente são representadas por um número limitado de pixels ou segmentos (às vezes apenas um) nos dados dos sensores ópticos utilizados, e com o objetivo de evitar generalizações excessivas (MAXWELL et al., 2018), em casos em que diferentes ajustes de “K” resultaram em pontuações de F-score semelhantes, optamos por selecionar o menor valor de “K” que proporcionasse o melhor resultado de F-score. Este critério está alinhado com as descobertas de Than Noi & Capas (2017), os quais, ao mapearem o uso da Terra no Vietnã através da classificação de imagens do sensor Sentinel-2 MSI com o algoritmo K-NN, observaram os melhores resultados ao utilizarem $k = 1$.

O parâmetro "C" do algoritmo SVM revelou-se mais sensível aos ajustes em comparação com os parâmetros ajustados de RF e K-NN, demonstrando uma variação mais significativa com cada valor de "C" testado para obter os melhores resultados para a métrica F-score em cada um dos conjuntos de dados utilizados, conforme indicado na Tabela 09. Realizamos testes com valores de "C" variando de 0,1 a 1.000.

Ao analisarmos os conjuntos de dados compostos pelos dados Cbers 4A WPM, tanto com quanto sem a incorporação do NDVI, com uma resolução espacial de oito metros e classificados com a técnica Pixel a Pixel, observamos que os maiores valores de F-score foram alcançados à medida que aumentávamos os valores de "C". No entanto, a partir do limite de 100, os resultados para a métrica F-score começaram a declinar.

Ao gerarmos os modelos de classificação com o conjunto de dados "Planet-multi (Geo)", observamos que os resultados para a métrica F-score foram semelhantes ao utilizarmos valores de "C" variando entre 0,1 e 1000. Com o conjunto de dados "Sentinel-4B-

(PP)", os resultados de F-score foram semelhantes para valores de "C" variando entre 01 e 10. Considerando que o parâmetro "C" controla a flexibilidade da margem responsável pela classificação das amostras para esses dois conjuntos de dados supracitados, optamos por adotar valores maiores de "C" com o intuito de proporcionar margens mais estreitas e menos violações, conforme apontado por Cortes & Vapnik (1995); Maxwell et al. (2018) e Vargas Junior (2020).

6.4 VALIDAÇÃO ATRAVÉS DA LOCALIZAÇÃO DA INFRAESTRUTURA INSTALADA E DOS DADOS LIDAR

De acordo com Crosta (1992), um dos principais desafios da classificação de imagens é a simplificação considerável em relação à complexidade abrangente presente em uma cena de satélite. Em alguns casos, pode-se chegar ao ponto de definir classes que não são distintas com base nos dados multiespectrais disponíveis. Daí a importância de verificar os resultados das classificações em comparação com dados de referência confiáveis.

Embora Breiman (2001) tenha argumentado que as estimativas OOB são imparciais e podem eliminar a necessidade de um conjunto de teste separado, um estudo realizado por Cánovas et al. (2017) demonstrou que a aplicação da técnica OOB tende a superestimar a precisão e subestimar os erros de omissão e comissão.

Neste estudo, empregamos dois conjuntos de dados externos para avaliar as classificações realizadas com sensores ópticos: um proveniente de levantamento aéreo realizado com o sensor Lidar, e outro, composto pela localização da infraestrutura instalada, conforme apresentados no Capítulo 06.

No que se refere à validação em relação à localização da infraestrutura instalada, nosso objetivo foi quantificar a sobreposição entre essas estruturas e as clareiras mapeadas com os sensores ópticos. Nossa intenção é responder à seguinte pergunta: qual é a proporção das estruturas instaladas em campo que foi detectada nos mapeamentos das clareiras utilizando sensores ópticos?

Em relação ao mapeamento das estradas, considerando tratar-se de estruturas lineares, foi empregado o algoritmo Interseção, nativo no Qgis, para extrair os segmentos das estradas principais e secundárias que coincidem com as clareiras identificadas nas classificações das imagens. Isso permitiu calcular o comprimento total das estradas que se sobrepõem às clareiras mapeadas.

Em relação aos pátios de estocagem, foi considerada para a avaliação da sobreposição um buffer de 20 metros em torno da localização de cada pátio instalado. Essa análise visou verificar quais pátios, mesmo que parcialmente, se sobrepõem às clareiras mapeadas através da classificação das imagens capturadas pelos sensores ópticos. A escolha desse valor de buffer se baseia nas dimensões recomendadas para essas estruturas, de 20 m x 25 m (IBAMA, 2007). Essa dimensão apresenta valores bastante coincidentes com as medições realizadas em campo pela empresa concessionária (PATAUÁ, 2021).

O levantamento aéreo com sensor Lidar abrangeu uma área de 500 hectares, equivalente a 16,8% da UPA 4D, que denominamos como Área de Controle (AC) (Figura 05). Todos os mapeamentos das clareiras em formato raster, obtidos a partir das imagens ópticas, foram recortados para serem aplicados e comparados a essa área.

Para realizar o mapeamento das clareiras florestais a partir do processamento da nuvem de pontos com dados Lidar, é necessário gerar um modelo tridimensional em formato raster denominado Modelo de Altura de Dossel (MAD). O MAD é gerado a partir de outros dois modelos tridimensionais, também em formato raster, o Modelo Digital de Superfície (MDS), que representa todos os pulsos a laser que retornaram ao sensor, e o Modelo Digital de Terreno (MDT), resultado da filtragem dos pulsos que atingiram o solo (D'OLIVEIRA et al., 2012; LOCKS, 2017) (Figura 25).

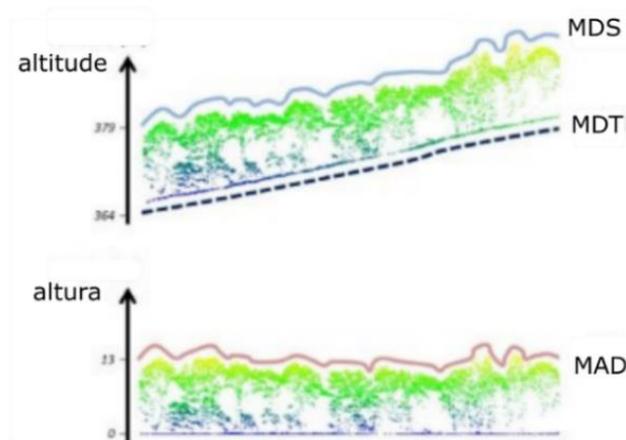
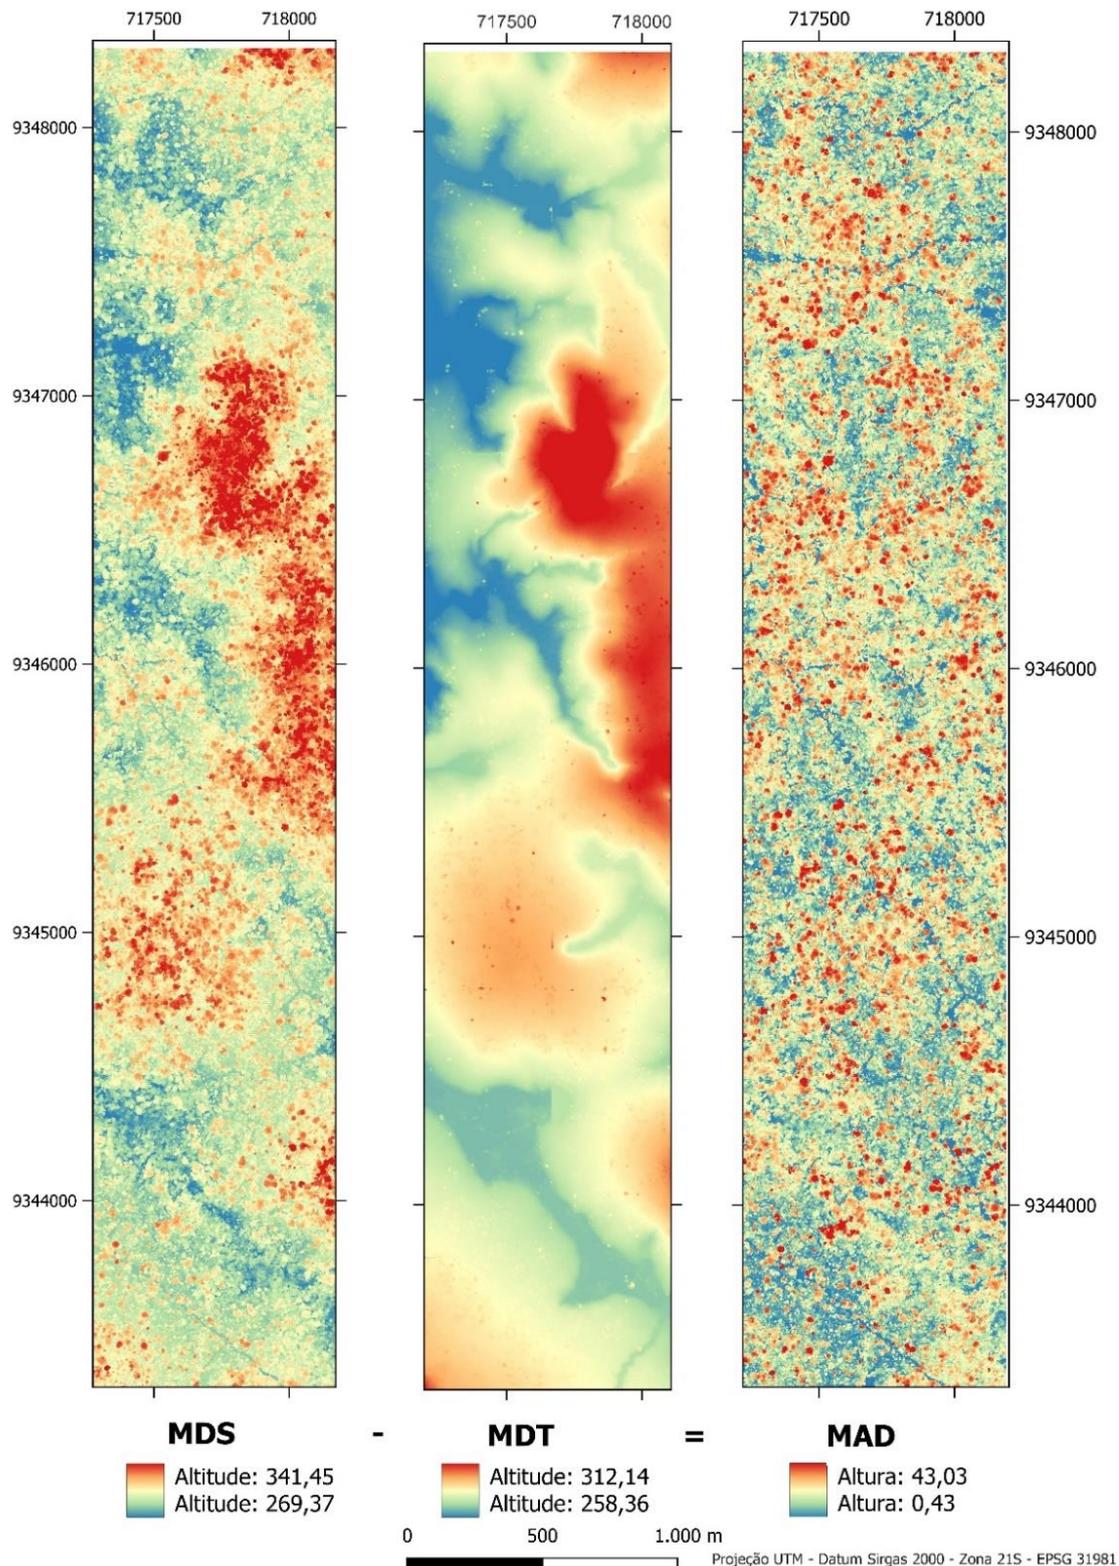


Figura 25. Modelo de Altura de Dossel (adaptado de MICHEZ et al., 2016).

Os dados Lidar em formato de nuvem de pontos foram disponibilizados por meio de 14 faixas de mapeamento. Nesse contexto, foram gerados MDS individualmente para cada uma dessas faixas. Posteriormente esses MDS foram combinadas em um mosaico contemplando toda a AC. Os MDS foram gerados com uma resolução espacial de um metro, utilizando o algoritmo Lidar Digital Surface Model (LSM), disponível no complemento Whitebox Tools (WTB) no Qgis.

Para gerar o MDT em cada faixa, os pulsos a laser que alcançaram o solo foram filtrados utilizando o algoritmo FilterLidarClasses disponível no WTB. Os MDT também foram criados com uma resolução de um metro por meio do LSM, e em seguida, unidos em um mosaico contemplando toda a AC (Figuras 26 a 28).



Figuras 26 a 28. Modelos tridimensionais em formato raster gerados com os dados Lidar.

O MAD permite representar as alturas das árvores, eliminando a influência da topografia. Dessa forma, as clareiras são mapeadas com base nas diferenças de altura entre os pixels do MAD. No entanto, não existe um consenso sobre o limite de altura a ser adotado para definir o que se constitui uma clareira.

Diversos estudos adotam a categorização de altura da vegetação proposta pela Sociedade Americana de Fotogrametria e Sensoriamento Remoto. Segundo essa classificação, a vegetação baixa tem altura entre 0,5 e dois metros, a vegetação média varia de dois a cinco metros, e a vegetação alta possui altura acima de cinco metros (KHOSRAVIPOUR et al., 2014; ALJUMAILY et al., 2019; ŠTULAR et al., 2021).

O limite de altura de dois metros para delimitação de clareiras com dados Lidar, foi adotado, por exemplo, por Locks e Matricardi (2019) em estudo realizado em três Flonas sob concessão florestal na Amazônia. Embora, estudos como os realizados por Hunter et al. (2015) e Dalagnol et al. (2019) tenham delimitado clareiras com altura inferior a dez metros, optamos por não utilizar esse valor, devido termos interpretado que com esse limite de altura, seriam incluídos como clareiras muitos pixels que representam árvores menores que compõem o sub-bosque florestal.

Deve-se ressaltar, ainda, que os mapeamentos a laser com alta densidade de pulsos, como os dados utilizados nesta pesquisa, têm a capacidade de identificar pequenas frestas entre as copas das árvores no dossel, mas nem todos esses espaços devem ser considerados como clareiras florestais. Dessa forma, utilizamos dois conjuntos de mapas diferentes gerados com dados Lidar para validação das classificações realizadas com os sensores ópticos. Um deles delimita as clareiras com uma área mínima de 20 m², enquanto o outro inclui clareiras com área mínima de até 40 m², todavia, ambos apresentam o mesmo limite vertical de dois metros.

Deve-se destacar que as diferenças significativas na forma de capturar informações entre os sensores ópticos e a laser podem levar a erros de avaliação nas áreas sobre corpos d'água, uma vez que, a depender do tamanho das áreas e da resolução espacial, os sensores ópticos, possuem a capacidade de identificá-los devido às disparidades entre as respostas espectrais da água em comparação com as da vegetação e do solo exposto. No entanto, os sensores Lidar não captam informações espectrais, mas somente a localização tridimensional dos objetos interceptados pelos pulsos de laser. Desta forma, áreas sobre cursos d'água descobertas pelo dossel florestal podem ser classificadas como clareiras nestes mapeamentos.

Nesse contexto, visando assegurar uma comparação mais fidedigna entre os mapeamentos realizados com sensores ópticos e a laser, procedemos a exclusão das áreas correspondentes aos canais de drenagem, conforme a localização informada pela empresa concessionária, totalizando cerca de 10% da AC (PATAUÁ, 2019). A Figura 29 apresenta esquematicamente a sequência de procedimentos realizados com os dados oriundos do aerolevanteamento utilizando sensor Lidar.

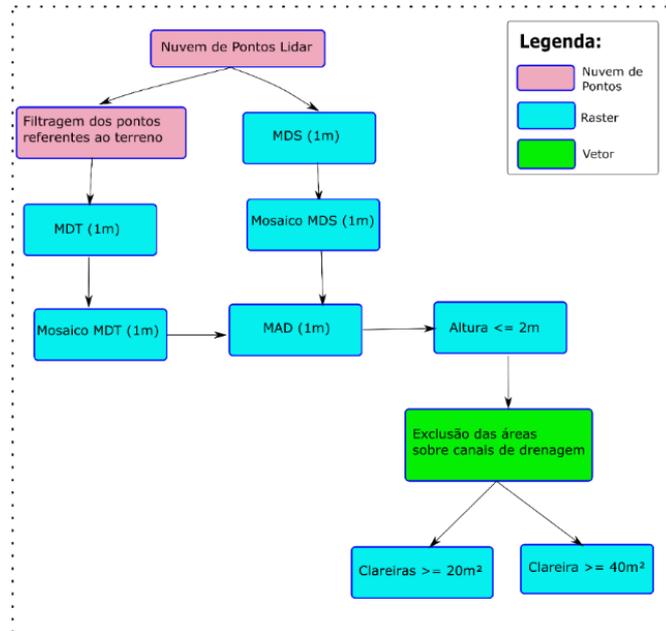


Figura 29. Fluxo de trabalho do mapeamento das clareiras com dados Lidar.

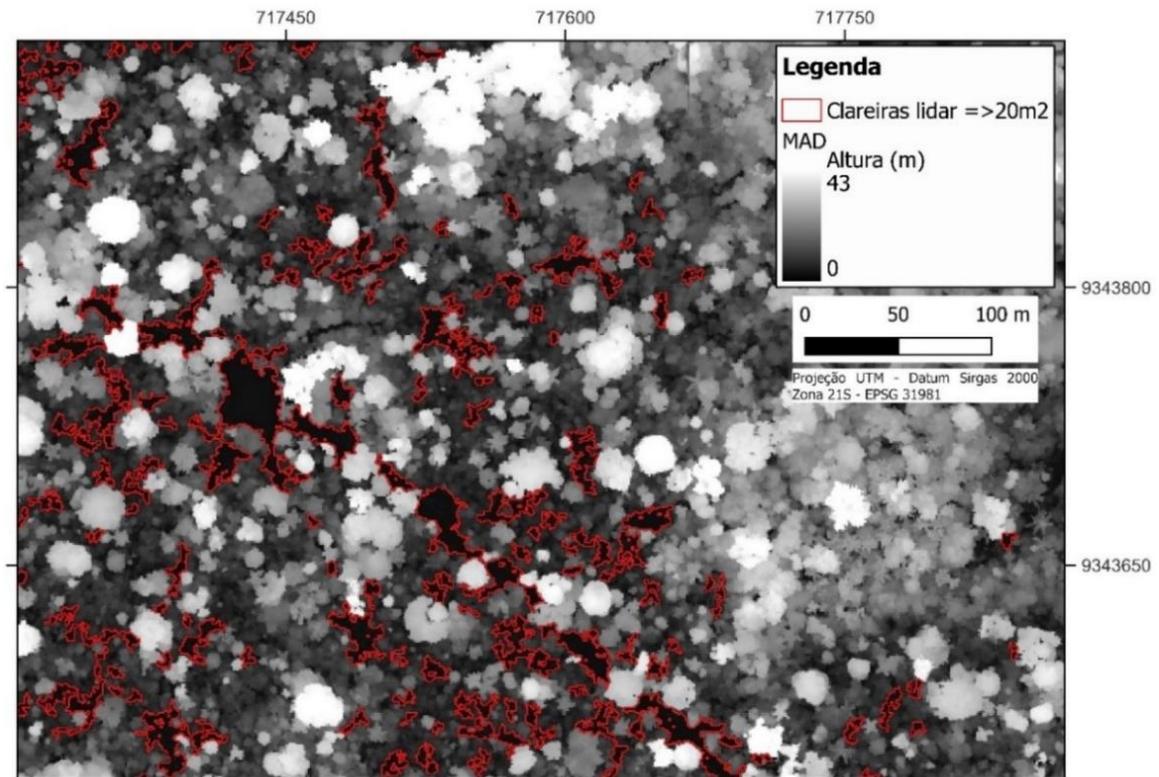


Figura 30. Exemplo de clareiras com no mínimo 20m² mapeadas com dados Lidar.

Com o objetivo de validar a classificação das clareiras florestais associadas à presença de infraestruturas, foram selecionadas as aberturas no dossel identificadas tanto por dados Lidar, quanto por sensores ópticos que se sobrepõem às estradas e pátios de estocagem na AC. Foram selecionadas as clareiras mapeadas que interceptam as estradas, assim como aquelas que se sobrepõem a um buffer com um raio de 20 metros, criado com base na localização dos pátios de estocagem instalados (PATAUÁ, 21021).

Foram considerados os polígonos em sua totalidade, desde que sobrepostos, ainda que parcialmente, às infraestruturas instaladas em campo. Após a seleção das clareiras, os procedimentos subsequentes seguem o mesmo padrão de validação com dados Lidar aplicado a todas as clareiras mapeadas, conforme explicado no item anterior. No entanto, visando simplificar o fluxo de trabalho, e em razão do maior tamanho das aberturas no dossel associadas à infraestrutura, as métricas de concordância foram calculadas exclusivamente para as clareiras mapeadas com dados Lidar com no mínimo 40 m².

6.5 MÉTRICAS DE CONCORDÂNCIA UTILIZADAS PARA VALIDAÇÃO

Uma maneira prática de se avaliar o nível de concordância entre dois conjuntos de dados, que possibilita a obtenção de métricas de forma bastante flexível, é utilizando matriz de confusão. Essas matrizes possibilitaram a extração das seguintes métricas de concordância para avaliar a taxa de acerto das classificações: Precisão, Recall, F-score e Acurácia Geral. Essas métricas foram geradas por meio das ferramentas `ComputeConfusionMatrix` presente no complemento OTB e `r.kappa` disponível no complemento GRASS.

A métrica Precisão apresenta a proporção dos dados classificados como clareiras que eram realmente clareiras. Portanto, busca responder a seguinte questão: dentre todas as clareiras mapeadas, quantas, de fato, eram clareiras?

O Recall indica a proporção das amostras que eram, de fato, clareiras e foram corretamente classificadas como tal. O Recall é conhecido como taxa de detecção e busca responder a seguinte pergunta: quantas das clareiras que deveriam ser identificadas foram corretamente classificadas?

O F-score fornece uma única medida que combina tanto a Precisão quanto o Recall, calculada como a média harmônica dessas duas métricas. Para Mário Filho (2023), em alguns problemas, é mais importante maximizar o Recall, enquanto em outros é mais importante a

precisão. Desta forma, a métrica F-score é útil porque é capaz de equilibrar esses dois fatores, sendo mais versátil e informativo do que a Acurácia Geral.

A Acurácia Geral refere-se à proporção de todas as classificações corretas em relação ao número total de amostras para as duas classes, Clareira e Dossel. No entanto, Maxwell et al. (2018) advertem que as classes com menor representatividade no mapeamento tendem a ter pouca relevância nessa métrica.

A seguir estão as fórmulas (de 02 a 05) matemáticas utilizadas para o cálculo das métricas de concordância utilizadas para comparações dos mapeamentos das clareiras florestais realizados por meio das classificações das imagens ópticas em relação aos mapeamentos produzidos com os dados do aerolevanteamento realizado com o sensor Lidar.

$$\mathbf{Precisão} = \frac{VP}{VP + FP} \quad (02)$$

$$\mathbf{Recall} = \frac{VP}{VP + FN} \quad (03)$$

$$\mathbf{F-score} = \frac{2*(Precisão*Recall)}{Precisão + Recall} \quad (04)$$

$$\mathbf{Acurácia Geral} = \frac{VP + VN}{VP + FP + VN + FN} \quad (05)$$

Onde, VP = Verdadeiro Positivo; VN = Verdadeiro Negativo; FP = Falso Positivo e FN = Falso Negativo.

7. RESULTADOS

7.1 QUANTIFICAÇÃO DAS CLAREIRAS FLORESTAIS MAPEADAS COM SENSORES ÓPTICOS E VALIDAÇÃO PELO MÉTODO OOB.

A área percentual média de clareiras mapeadas nas 42 classificações de imagens realizadas com os sensores ópticos foi de 7,28% da área total da UPA 4D (2.975 ha). O valor médio da métrica F-score, calculado pelo método OOB, para a classe de clareiras, considerando todas as classificações realizadas com os sensores ópticos, foi de 0,99. A Tabela 10 mostra os resultados dos mapeamentos de clareiras na UPA 4D, exibindo as médias obtidas com os três algoritmos de classificação adotados em cada um dos 14 conjuntos de dados classificados. Esses conjuntos estão listados em ordem crescente com base na área total de clareiras mapeadas. O desvio padrão reflete as variações em relação aos três algoritmos de classificação empregado.

Conjunto de dados	Clareiras (ha)	UPA 4D (%)	DP % UPA	F-score OOB Clareira	DP F-score OOB Clareira
Cbers-8m-multi(PP)	157,434	5,290	0,007	0,995	0,001
Cbers-8m-multi+NDVI(PP)	156,292	5,251	0,007	0,995	0,002
Cbers-2m-multi(PP)	55,070	1,850	0,002	0,993	0,002
Cbers-2m-multi+NDVI(PP)	50,308	1,690	0,000	0,990	0,002
Cbers-2m-multi(Geo)	154,124	5,178	0,020	0,986	0,016
Cbers-2m-multi+NDVI(Geo)	229,965	7,727	0,040	0,975	0,021
Planet-multi(PP)	494,086	16,601	0,051	0,985	0,015
Planet-multi+NDVI(PP)	488,128	16,400	0,044	0,993	0,002
Planet-multi(Geo)	649,215	21,813	0,077	0,953	0,016
Planet-multi+NDVI(Geo)	425,009	14,280	0,029	0,937	0,050
Sentinel-4B-(PP)	200,393	6,733	0,014	0,964	0,008
Sentinel(4B+NDVI)	276,532	9,291	0,041	0,979	0,005
Sentinel-10B(PP)	323,260	10,861	0,070	0,989	0,001
Sentinel-10B+NDVI(PP)	305,943	10,279	0,059	0,983	0,008

Tabela 10. Percentual de clareiras mapeadas em relação à área da UPA 4D e resultados da métrica F-score (OOB) da classe clareira em cada conjunto de dados classificados com sensores ópticos.

A Figura 31 apresenta as médias dos resultados de F-Score obtidas pelo método OOB, agrupados por tipo de sensor utilizado. Os resultados foram de 0,989 para o sensor CBERS-4A WPM, de 0,967 para as classificações realizadas com o sensor PlanetScope e de 0,929 para o sensor Sentinel-2 MSI. É importante destacar que esses valores se referem apenas à validação da classe clareira; os valores de Acurácia Geral obtidos por este método foram ainda mais elevados. É notável que os valores de F-score calculadas pelo método OOB permanecem em níveis muito altos, independentemente das amplas flutuações nas áreas calculadas.

Os desvios padrão de F-score (OOB) em relação ao tipo de algoritmo utilizado permaneceram consistentemente baixos. Para esta métrica, o maior desvio (0,05) foi apresentado pelo conjunto de dados "Planet-multi+NDVI(Geo)". Nesse caso, a classificação usando o algoritmo SVM foi a única, entre as 42 classificações realizadas, a apresentar um valor de F-score (OOB) inferior a 0,9, contribuindo para o aumento do desvio padrão nesse conjunto.

As áreas de clareiras mapeadas apresentam diferenças significativas entre os diversos conjuntos de dados utilizados. Essa disparidade é mais acentuada em decorrência do tipo de sensor do que em razão das outras variações nos conjuntos de dados, técnicas de mapeamento e algoritmos de classificação. A média das áreas totais das clareiras mapeadas usando imagens PlanetScope é 85,9% maior do que os resultados obtidos com Sentinel-2 MSI e 283,78% maior que a média dos mapeamentos realizados com Cbers 4A WPM (Figura 31).

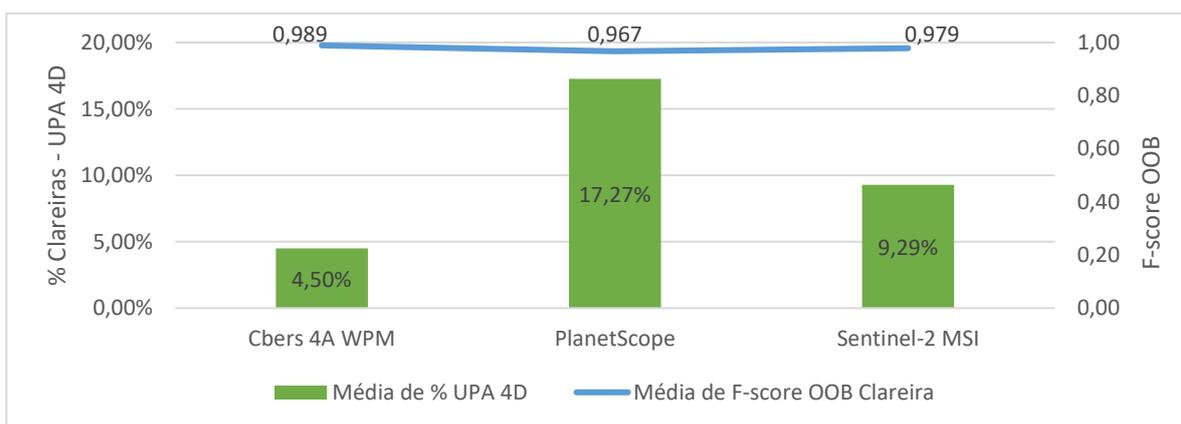


Figura 31. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) agrupadas por tipo de sensor óptico utilizado.

Conforme apresentado na Figura 32, a disparidade entre a área total de clareiras mapeadas entre os sensores PlanetScope e Cbers 4A WPM se torna ainda mais acentuada (833,51%) quando compararmos a média de todos os mapeamentos conduzidos com PlanetScope em relação àqueles realizados com conjuntos de dados Cbers 4A WPM, com resolução espacial de dois metros e a utilização da técnica Pixel a Pixel.

Nos mapeamentos com o sensor CBERS-4A WPM, aqueles realizados com uma resolução espacial de dois metros apresentaram, em média, uma área total de clareiras 28,22% menor em comparação com os realizados com o mesmo sensor, mas com oito metros de resolução espacial. Além disso, as classificações com o CBERS-4A WPM em uma resolução espacial mais alta, associadas ao uso da técnica Geobia, demonstraram, em média, uma área total 264,41% maior em comparação com as classificações utilizando a técnica de Pixel a Pixel.

Em termos da área total das clareiras, ao utilizarmos conjuntos de dados do PlanetScope, a aplicação da técnica Geobia resultou em um aumento médio de 9,4% em comparação com as classificações realizadas por meio da técnica Pixel a Pixel. Em relação à inclusão do NDVI nos conjuntos de dados deste sensor, as classificações que incorporaram o índice de vegetação apresentaram, em média, uma área de clareiras 25,22% menor em comparação com as classificações realizadas sem sua inclusão.

Os mapeamentos realizados com a imagem Sentinel-2 MSI exibiram, em geral, áreas totais de clareiras em um nível intermediário, mais próximas à média obtida pelas 42 classificações realizadas com sensores ópticos. No entanto, é importante destacar que a inclusão das seis bandas espectrais originalmente com resolução espacial de 20 metros, reamostradas para 10 metros, resultou em um aumento médio de 31,96% na área total de clareiras mapeadas. Esse aumento veio acompanhado de uma maior variação nos resultados, dependendo do tipo de algoritmo utilizado.

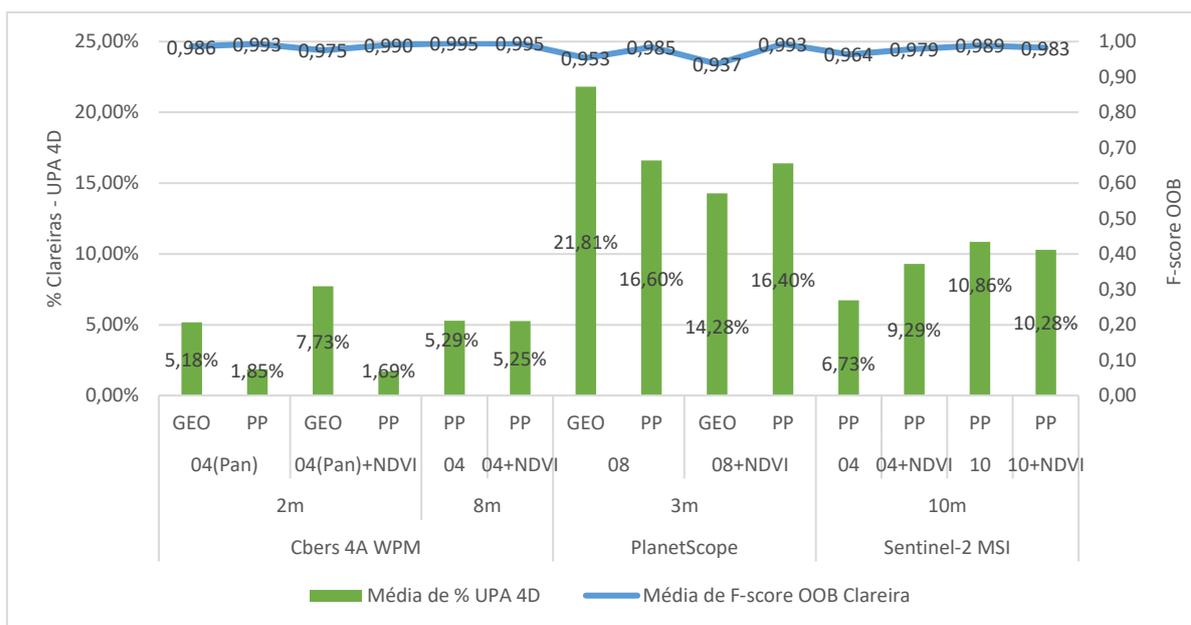


Figura 32. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe clareira, agrupadas por tipo de sensor óptico, resolução espacial, bandas espectrais e técnica de mapeamento empregadas.

A inclusão do NDVI ao conjunto de dados composto apenas pelas quatro bandas espectrais do sensor Sentinel-2 MSI, originalmente com dez metros de resolução espacial, resultou em um aumento médio de 39,03% na área total de clareiras mapeadas. No entanto, em relação ao conjunto de dados compostos por 10 bandas espectrais, a inclusão do NDVI resultou em uma diminuição de 5,64% da área total de clareiras mapeadas.

Ao analisarmos os resultados referentes ao cálculo das áreas totais de clareiras mapeadas com base apenas no tipo de algoritmo utilizado (Figura 33), observamos que os

menores quantitativos estão, em geral, associados ao uso do algoritmo K-NN. Por outro lado, os valores mais altos estão relacionados ao uso do algoritmo SVM, com uma discrepância percentual média de 48,8% entre esses dois algoritmos, considerando todos os sensores ópticos utilizados.

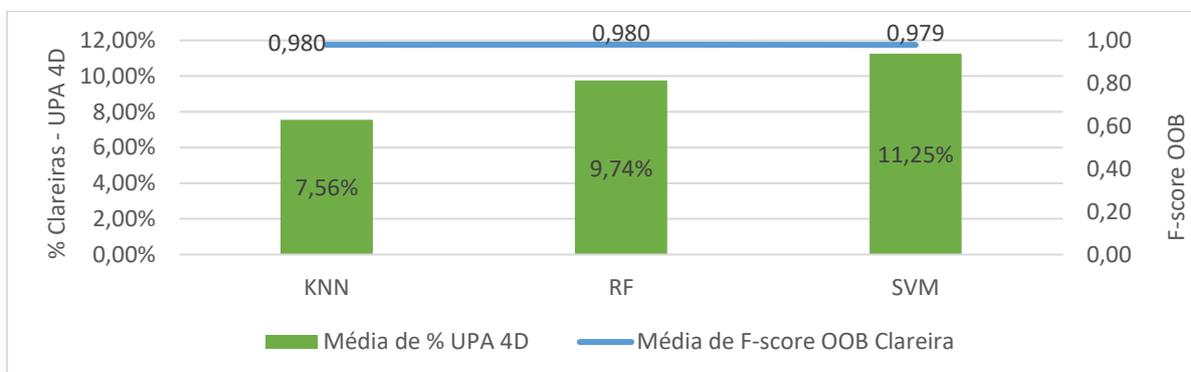


Figura 33. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe clareira agrupados por tipo de algoritmo utilizado.

Ao examinar a combinação dos resultados das áreas de clareiras mapeadas, considerando tanto o tipo de algoritmo quanto o sensor óptico empregado (Figura 34), fica evidente que, para todos os algoritmos utilizados, as maiores médias das áreas de clareiras mapeadas ocorreram ao utilizar o sensor PlanetScope. Em contrapartida, os valores mais baixos foram consistentemente registrados em todos os algoritmos quando o sensor Cbers 4A WPM foi empregado.

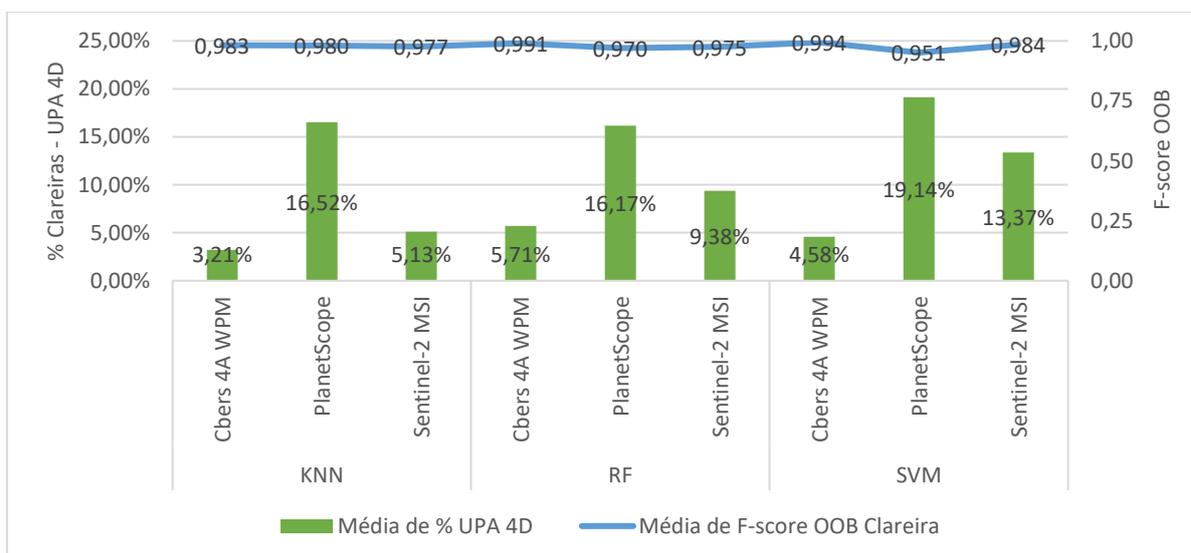


Figura 34. Valor percentual médio das clareiras mapeadas em relação à área da UPA 4D e suas respectivas estimativas F-score (OOB) para a classe Clareira agrupados por algoritmo e sensor óptico utilizado.

A Tabela 11 demonstra que, em termos de hierarquia, entre os diferentes conjuntos de dados utilizados, os resultados das áreas totais de clareiras mapeadas com os sensores ópticos em toda a UPA 4D são compatíveis com os resultados obtidos para a AC. No entanto, todos os conjuntos mostraram uma área proporcionalmente menor ocupada por clareiras em

comparação com os valores apresentados para a totalidade da UPA 4D. Em média, o percentual de áreas ocupadas por clareiras mapeadas pelos sensores ópticos na AC foi de 7,67%, em comparação com os 8,51% registrados para toda a UPA 4D. Pode-se inferir que a ausência de estradas primárias na AC contribui, pelo menos em parte, para essa redução que se revelou consistente em todos os conjuntos de dados empregados com sensores ópticos.

Conjunto de dados	Média de clareiras UPA 4D (%)	Média de clareiras AC (%)
Planet-multi(Geo)	21,81%	20,49%
Planet-multi(PP)	16,60%	16,07%
Planet-multi+NDVI(PP)	16,40%	15,31%
Planet-multi+NDVI(Geo)	14,28%	13,02%
Sentinel-10B(PP)	10,86%	8,89%
Sentinel-10B+NDVI(PP)	10,28%	8,20%
Sentinel(4B+NDVI)	9,29%	7,80%
Cbers-2m-multi+NDVI(Geo)	7,73%	7,54%
Sentinel-4B-(PP)	6,73%	6,30%
Cbers-8m-multi(PP)	5,29%	4,59%
Cbers-8m-multi+NDVI(PP)	5,25%	4,55%
Cbers-2m-multi(Geo)	5,18%	4,47%
Cbers-2m-multi(PP)	1,85%	1,42%
Cbers-2m-multi+NDVI(PP)	1,69%	1,33%
Média Geral	8,51%	7,67%

Tabela 11. Percentual médio da área ocupada pelas clareiras mapeadas com cada conjunto de dados em relação a UPA 4D e a AC. São utilizadas as médias dos resultados obtidos com cada algoritmo de classificação.

7.2 VALIDAÇÃO ATRAVÉS DA LOCALIZAÇÃO DA INFRAESTRUTURA

Para avaliar a capacidade dos mapeamentos realizados com sensores ópticos em identificar as clareiras relacionadas à infraestrutura instalada na UPA 4D, utilizamos os dados de localização dos pátios de estocagem, Estradas Principais (EP) e Estradas Secundárias (ES) fornecidos pela empresa concessionária em formato vetorial (PATAUA, 2021). É importante salientar que, nessa validação, não buscamos medir a área ocupada, mas sim a capacidade de detecção dessas estruturas em cada processo de classificação realizado com os sensores ópticos.

A Tabela 12 fornece os resultados dos percentuais médios relacionados à detecção da infraestrutura instalada nos 14 conjuntos de dados classificados com sensores ópticos. Esses resultados foram ordenados com base na capacidade de detecção das estradas secundárias, estruturas mais difíceis de serem identificadas, dentre as avaliadas.

Conjunto de dados	Pátios (%)	EP (%)	ES (%)
Planet-multi+NDVI(PP)	100,000	77,113	53,498
Planet-multi(PP)	100,000	76,150	52,937
Planet-multi(Geo)	99,713	73,467	52,058
Planet-multi+NDVI(Geo)	98,851	64,185	42,265
Sentinel-10B(PP)	99,713	65,674	38,061
Sentinel-10B+NDVI(PP)	100,000	65,510	37,873
Cbers-2m-multi+NDVI(Geo)	99,713	65,346	37,798
Sentinel(4B+NDVI)	99,617	61,203	37,506
Sentinel-4B-(PP)	99,138	52,425	36,585
Cbers-2m-multi(Geo)	99,138	60,340	32,703
Cbers-8m-multi+NDVI(PP)	100,000	54,060	29,736
Cbers-8m-multi(PP)	100,000	53,911	29,652
Cbers-2m-multi(PP)	99,713	42,865	18,852
Cbers-2m-multi+NDVI(PP)	99,713	41,067	18,091
Média Geral	99,713	62,694	37,652

Tabela 12. Percentual médio da infraestrutura detectada nas classificações realizadas com sensores ópticos em cada conjunto de dados classificados com sensores ópticos.

Conforme ilustrado na Figura 35, a detecção das infraestruturas está diretamente relacionada a área total de clareiras mapeadas. Dessa forma, os mapeamentos realizados com dados PlanetScope apresentaram os melhores resultados, enquanto aqueles realizados com Cbers 4A WPM obtiveram os piores, especialmente quando a resolução espacial de dois metros e a técnica Pixel a Pixel foram empregadas.

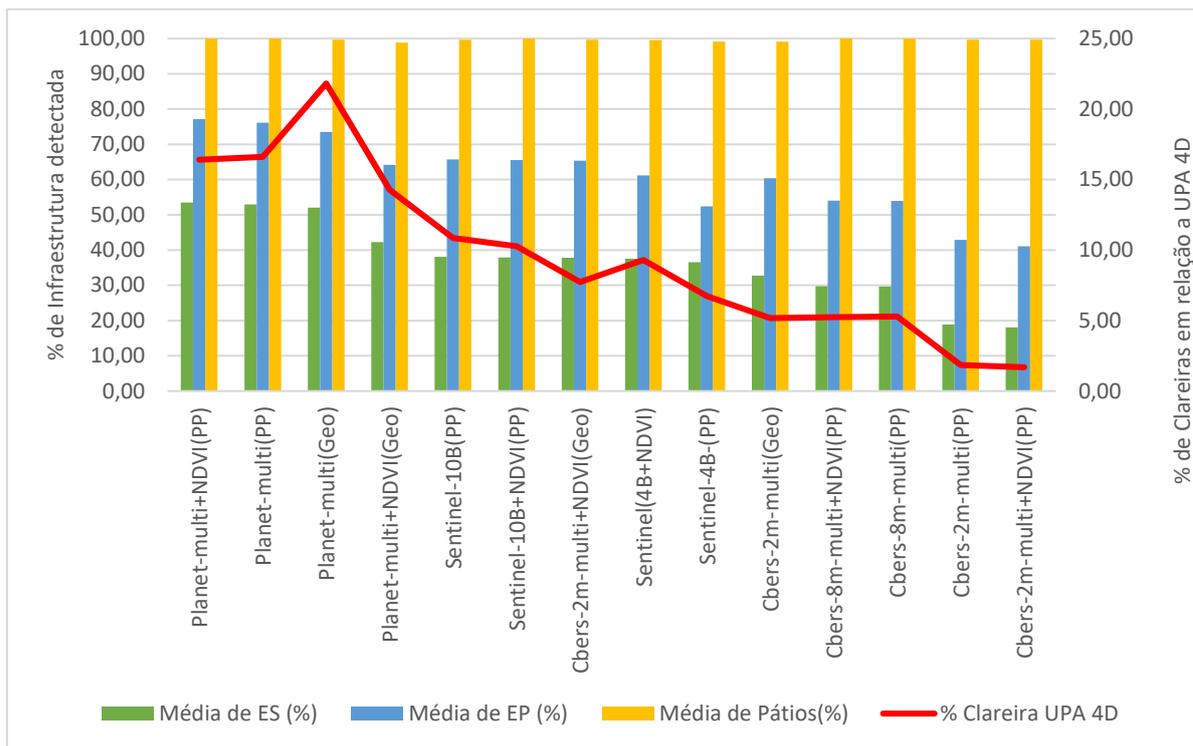


Figura 35. Percentual médio da infraestrutura detectada e valor percentual médio das clareiras mapeadas em relação à área da UPA 4D em cada conjunto de dados classificados com sensores ópticos.

Ao agruparmos os resultados por tipo de sensor, resolução espacial e técnica de mapeamento, observamos que as classificações realizadas com base nos dados PlanetScope demonstraram, em média, os mais altos percentuais de detecção para ambas as técnicas de mapeamento empregadas. Essa tendência foi ligeiramente mais acentuada na abordagem Pixel a Pixel, como evidenciado na Figura 36.

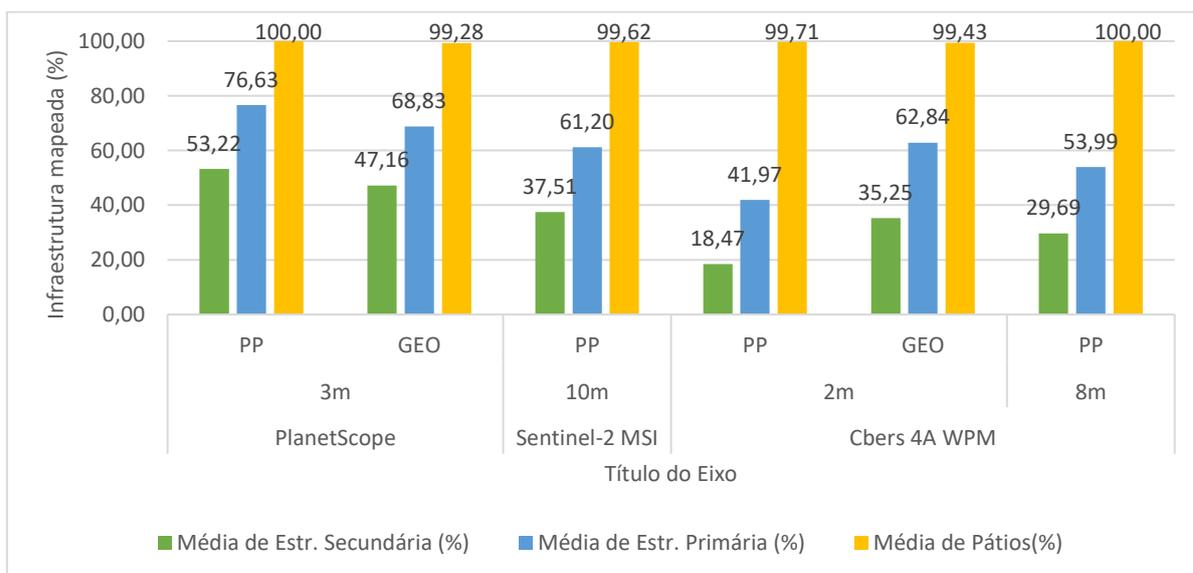


Figura 36. Percentual médio da infraestrutura detectada nas classificações realizadas com sensores ópticos, agrupado por sensor, resolução espacial e técnica de mapeamento empregada.

A detecção média de pátios de estocagem alcançou mais de 99% em todas as 42 classificações realizadas com os sensores ópticos. Em 27 dessas classificações, todos os pátios foram identificados, enquanto em 15 classificações apenas um pátio foi omitido. Em relação às estradas, a média de mapeamento foi de 59,19% para as estradas principais e de 37,51% para as secundárias.

A média de segmentos de estradas mapeados com o sensor PlanetScope foi de 72,73% para as estradas principais e 40,19% para as secundárias. Nos mapeamentos com dados Sentinel-2 MSI, os resultados foram, respectivamente, de 61,20% e 37,51%, enquanto nos mapeamentos com o CBERS-4A WPM, foram de 52,93% e 27,81%.

Essa disparidade na taxa de detecção entre as estradas secundárias e principais era esperada, uma vez que as estradas secundárias são estruturas temporárias, utilizadas exclusivamente durante o período de exploração florestal. Em contraste, as estradas principais, mais largas, desempenham um papel permanente ao conectar diversas UPAs, além de serem empregadas para atividades contínuas de monitoramento e controle ambiental após a conclusão do período de exploração.

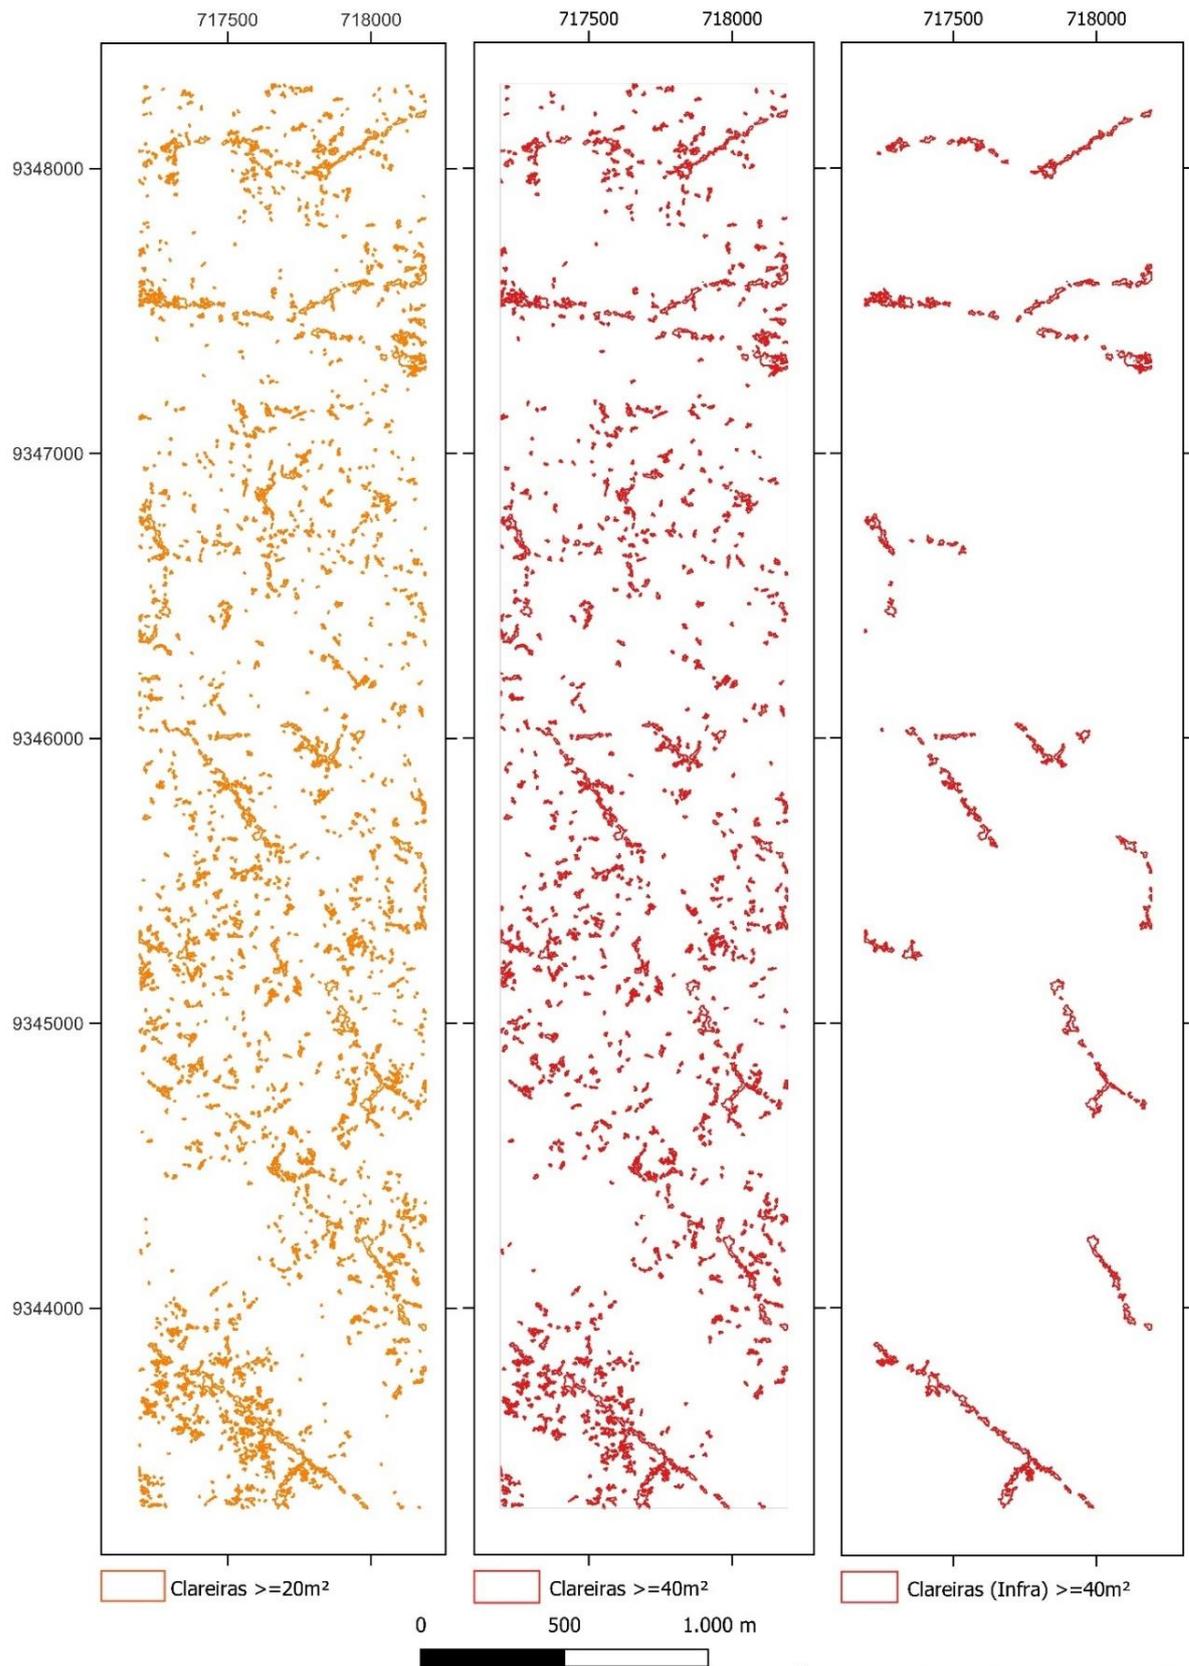
7.3 VALIDAÇÃO COM O USO DE DADOS LIDAR AEROTRANSPORTADOS

Essas avaliações foram conduzidas sobre uma parcela da UPA 4D que denominamos de Área de Controle (AC), e abrange uma extensão de 449,44 ha, já descontando as áreas sobre os canais de drenagem, conforme detalhado no Capítulo 06.

De acordo com a definição proposta por Brokaw (1982), estabelecemos que as clareiras delimitadas com base em dados Lidar deveriam apresentar uma altura medida pelo MAD igual ou inferior a dois metros. Com base nessa diretriz, efetuamos dois mapeamentos distintos: um deles identificou clareiras com uma área mínima de 20 m², enquanto o outro englobou clareiras com uma área mínima de 40 m². Os mapeamentos das clareiras realizados com os dados Lidar sobre a AC resultaram em uma taxa de abertura do dossel de 4,57%, considerando clareiras com área mínima de 20 m² e 4,08%, considerando aberturas mínimas com 40 m².

A área média ocupada por cada clareira nos mapeamentos com polígonos mínimos de 20 m² foi de 106,65 m² (mediana de 47 m²), enquanto nos mapeamentos com áreas mínimas de 40 m², foi de 164 m² (mediana de 82 m²). No que se refere a esse último mapeamento, considerando apenas as clareiras sobrepostas à infraestrutura, a área média foi de 579 m² (mediana de 288 m²). As clareiras de infraestrutura ou contíguas a ela, corresponderam a cerca de um terço da área total de clareiras mapeadas com dados Lidar. Os valores de mediana consideravelmente inferiores às médias das áreas das clareiras sugerem uma significativa ocorrência de clareiras em tamanhos menores do que a média do conjunto. As figuras 37 e 38 apresentam as clareiras mapeadas com dados Lidar, com áreas mínimas de 20 m² e 40 m². A Figura 39 apresenta as clareiras sobrepostas à infraestrutura com pelo menos 40 m².

É relevante ressaltar que, ao sobrepor o mapeamento das clareiras com dados Lidar à infraestrutura instalada, verifica-se que, mesmo com a utilização de nuvem de pontos com alta densidade, apenas 41% do comprimento total das estradas secundárias está sobreposto às aberturas no dossel mapeadas com Lidar. Isso indica que mais da metade da extensão das estradas secundárias abertas na AC permanece coberta pelo dossel florestal. Quanto aos pátios de estocagem, todos eles estão sobrepostos às clareiras mapeadas com dados Lidar. Como não foram instaladas estradas primárias na AC, não foi possível avaliar a taxa de detecção dessas estruturas usando Lidar.



Figuras 37 a 39. Mapeamentos das clareiras realizados com dados Lidar aerotransportados.

Ao analisar que a área percentual média ocupada pelas clareiras mapeadas com os sensores ópticos na AC foi de 7,67%, observamos que os mapeamentos realizados com esses

sensores tendem a superestimar as áreas de clareiras em comparação com os mapeamentos com dados Lidar em mais de 65%. Os conjuntos de dados compostos por sensores ópticos que apresentaram maior concordância com os percentuais de clareiras mapeadas com dados Lidar foram os dados CBERS-4A WPM, com resolução de oito metros, e com resolução de dois metros combinada com a aplicação da técnica Geobia.

No entanto, é fundamental destacar que avaliar a concordância entre os mapeamentos com base apenas na área total das clareiras não é um indicador adequado, uma vez que não considera se há correspondência espacial entre as clareiras identificadas pelos sensores ópticos e os dados Lidar. Dessa maneira, a sequência deste capítulo se concentrará nas métricas de concordância: Precisão, Recall e F-score, derivadas das matrizes de confusão geradas ao comparar os mapeamentos realizados com sensores ópticos e os mapeamentos com dados Lidar.

Os 42 mapeamentos das clareiras realizados com sensores ópticos recortados para AC foram comparados aos dois mapeamentos obtidos com dados Lidar, levando em consideração tamanhos mínimos de clareiras de 20 m² e 40 m². A diferença entre os resultados das validações devido aos tamanhos mínimos de clareiras estabelecidos com dados Lidar, em média, correspondeu a apenas 1,23% de F-score. Dessa forma, considerando a definição adotada (Brokaw, 1982) e com o intuito de simplificar a análise dos dados, os resultados apresentados correspondem à média aritmética dos resultados das métricas de concordância obtidas por cada classificação realizada com sensores ópticos em relação a ambos os conjuntos de mapeamentos produzidos com dados Lidar. É importante ressaltar que as métricas de concordância adotadas não se limitam à mera detecção das clareiras florestais, mas estão direcionadas a avaliar a semelhança de toda a geometria e o delineamento individual de cada clareira.

A Tabela 13 apresenta as médias dos resultados de validação utilizando dados Lidar agrupados para cada um dos 14 conjuntos de dados provenientes dos sensores ópticos. Os resultados estão ordenados de acordo com o valor de F-score. Em geral, os resultados das validações referente à classe clareira foram extremamente baixos. Os valores mais altos alcançados para cada uma das métricas, considerando as 42 classificações realizadas, ficaram abaixo de 40% para Precisão e Recall e abaixo de 20% para F-score. Observa-se na Tabela 13 que a ordem dos conjuntos de dados em relação à Precisão demonstra grande concordância com a apresentada pela métrica F-score, o que sugere que a Precisão tem uma influência predominante na composição dessa última métrica.

Conjunto de dados	Precisão média	Recall média	F-score média	Acur. Geral média
Cbers-2m-multi+NDVI(PP)	0,356	0,109	0,167	0,958
Cbers-2m-multi(PP)	0,349	0,113	0,170	0,957
Cbers-2m-multi(Geo)	0,171	0,165	0,161	0,934
Cbers-8m-multi+NDVI(PP)	0,145	0,153	0,148	0,932
Cbers-8m-multi(PP)	0,145	0,154	0,148	0,932
Cbers-2m-multi+NDVI(Geo)	0,127	0,198	0,143	0,909
Sentinel-4B-(PP)	0,109	0,156	0,127	0,917
Sentinel-10B(PP)	0,109	0,185	0,124	0,896
Sentinel(4B+NDVI)	0,108	0,171	0,124	0,904
Sentinel-10B+NDVI(PP)	0,106	0,173	0,122	0,901
Planet-multi+NDVI(Geo)	0,070	0,209	0,104	0,860
Planet-multi(PP)	0,067	0,246	0,104	0,836
Planet-multi(Geo)	0,063	0,295	0,103	0,800
Planet-multi+NDVI(PP)	0,063	0,216	0,096	0,840
Média Geral	0,142	0,182	0,132	0,898

Tabela 13. Valores médios das métricas de concordância agrupados para os 14 conjuntos de dados classificados com sensores ópticos.

No que diz respeito à Acurácia Geral, as validações com os dados Lidar obtiveram resultados excelentes. O valor mais baixo de Acurácia Geral entre as 42 classificações realizadas foi de 0,748 (Planet_8bandas_GEO_SVM), enquanto o mais alto foi de 0,958 (Cbers_2m_PP_K-NN). Considerando as médias por sensor óptico, os valores foram de 93,7, 90,4% e 83,4%, respectivamente, para os sensores Cbers 4A WPM, Sentinel-2 MSI e PlanetScope.

No entanto, a Acurácia Geral não é a métrica mais adequada para avaliar os resultados dos mapeamentos das clareiras florestais. Isso ocorre devido à predominância do dossel florestal como a cobertura principal na área de estudo, representando pelo menos cerca de 80% de toda a área mapeada, conforme os sensores ópticos e, aproximadamente, 95% segundo o mapeamento realizado com dados Lidar.

Além disso, a classe Dossel demonstra taxas de acerto significativamente mais altas, geralmente acima de 90% para Precisão e acima de 80% para Recall. Essa predominância do dossel afeta consideravelmente a Acurácia Geral, tornando-a consistentemente superior em detrimento das métricas de concordância específicas para a classe clareira. Nesse contexto, a Acurácia Geral oferece mais informações sobre o dossel do que sobre as clareiras florestais. Destaca-se que, embora as clareiras exerçam uma pequena influência no cálculo da Acurácia Geral, observa-se uma correlação entre essa métrica e as de Precisão e F-score. Classificações

que obtiveram maiores resultados nessas métricas também apresentaram valores mais altos em Acurácia Geral.

A análise da Precisão demonstra que os mapeamentos realizados com dados do sensor Cbers 4A WPM alcançaram os melhores resultados para essa métrica. Os seis conjuntos de dados classificados com a imagem Cbers 4A WPM demonstraram maior precisão em comparação a todos os outros sensores ópticos utilizados. As classificações com Cbers 4A WPM apresentaram, em média, valores 99% maior em relação aos mapeamentos realizados com Sentinel-2 MSI e 225,75% maior em comparação a média dos mapeamentos realizados com dados PlanetScope (Figura 40).

A relação entre os resultados de Precisão e Recall revela uma inversão: conjuntos de dados com melhor desempenho em Precisão apresentam um desempenho inferior em Recall, e vice-versa. O Recall está diretamente associado à área total das clareiras mapeadas. Nesse contexto, os mapeamentos realizados com imagens PlanetScope se destacam em comparação aos outros sensores ópticos utilizados, especialmente em relação ao Cbers 4A WPM. Seis dos sete conjuntos de dados classificados com imagens PlanetScope exibiram os maiores valores de Recall. As classificações realizadas com o sensor PlanetScope apresentaram, em média, um valor de Recall 40% superior aos resultados obtidos com dados Sentinel-2 MSI e um desempenho 61,74% superior em relação à média de todas as classificações realizadas com Cbers 4A WPM. Por sua vez, os mapeamentos conduzidos com o sensor Sentinel-2 MSI apresentaram resultados intermediários para todas as métricas avaliadas em comparação aos outros dois sensores ópticos utilizados (Figura 40).

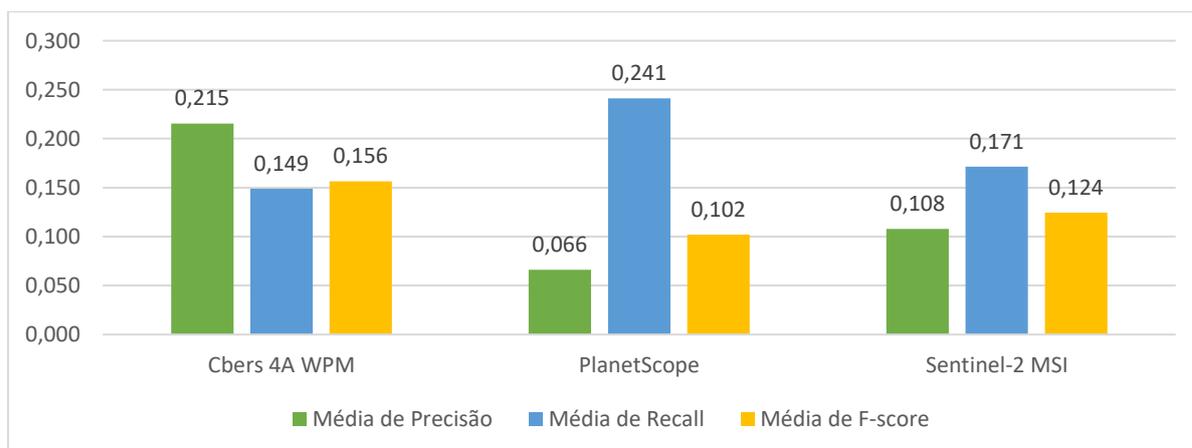


Figura 40. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC, agrupados por tipo de sensor

A Figura 41 apresenta os valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC, agrupados por tipo de sensor, resolução espacial, bandas espectrais e técnicas de mapeamento. Nele, podemos

observar que as classificações realizadas com a imagem Cbers 4A WPM com resolução espacial de dois metros, exibiram médias de Precisão que superaram em 73,10% as classificações realizadas com o mesmo sensor, porém com oito metros de resolução. Se considerarmos apenas as classificações realizadas com a técnica Pixel a Pixel, a diferença atinge 142,75%. A precisão das classificações realizadas com Cbers 4A WPM com resolução de dois metros e aplicando a técnica Pixel a Pixel, foi, em média, 136% maior do que aquelas realizadas por Geobia; em contrapartida, apresentaram, em média, redução de 63% no valor de Recall.

A inclusão do NDVI nos conjuntos de dados classificados pelo sensor Cbers 4A WPM com oito metros de resolução espacial não gerou diferenças significativas em nenhuma das métricas de concordância avaliadas. No entanto, nos conjuntos de dados com resolução de dois metros, a inclusão do NDVI resultou, em média, em uma diminuição de 7,43% na Precisão e de 7,09% no F-score. Por outro lado, observou-se um aumento médio de 10,79% no Recall.

Ao considerarmos especificamente os mapeamentos realizados com dados Cbers 4A WPM com dois metros de resolução espacial e o uso da técnica Pixel a Pixel, observamos que o valor médio da métrica Precisão é 433,33% maior em comparação ao resultado médio alcançado com os dados PlanetScope e 225,92% maior em relação à média dos mapeamentos realizados com dados Sentinel-2 MSI.

Ao analisar a métrica Recall nos mapeamentos com os dados Cbers 4A WPM, os resultados mais expressivos foram alcançados, em média, nas classificações realizadas com resolução espacial de dois metros e a aplicação da técnica Geobia. Os valores de Recall obtidos com o uso da técnica Geobia nesse sensor são 18,95% superiores, em média, em comparação às classificações realizadas com a resolução de oito metros e 63,96% superiores às obtidas, em média, quando a técnica Pixel a Pixel foi empregada nos conjuntos com dois metros de resolução.

O valor médio da métrica Recall obtido nos mapeamentos com PlanetScope é 117% maior em relação às classificações realizadas com Cbers 4A WPM com dois metros de resolução e o uso da técnica Pixel a Pixel. As classificações executadas com o sensor PlanetScope sem a inclusão do NDVI apresentaram, em média, um valor de Recall 26,76% superior em comparação com as classificações realizadas com o mesmo sensor com a inclusão do NDVI. A inclusão do NDVI com esse sensor, resultou em um ganho médio de 3,07% em Precisão e um ganho de 4% para F-score. Ao utilizar Geobia com os dados PlanetScope, houve

um aumento nos valores das três métricas de concordância para a classe de clareiras adotadas: 3,07% em relação à Precisão, 9,09% em relação ao Recall e 4% em relação ao F-score.

Em relação as classificações realizadas com o sensor Sentinel-2 MSI, a integração das bandas espectrais originalmente com 20 metros de resolução espacial reamostradas para 10 metros, resultou em um aumento médio de 9,14% na métrica Recall. No entanto, a integração de mais bandas espectrais culminou em redução nos valores de Precisão em 0,93% e de F-score de 2,44%. A incorporação do NDVI às classificações realizadas com o sensor Sentinel-2 MSI teve um impacto reduzido nos valores das métricas de concordância avaliadas para a classe clareira. A utilização do índice de vegetação culminou em um ganho para a métrica Recall de 1,18%, todavia, sua inclusão representou valores 1,86% menores de Precisão e 2,44% para a métrica F-score.

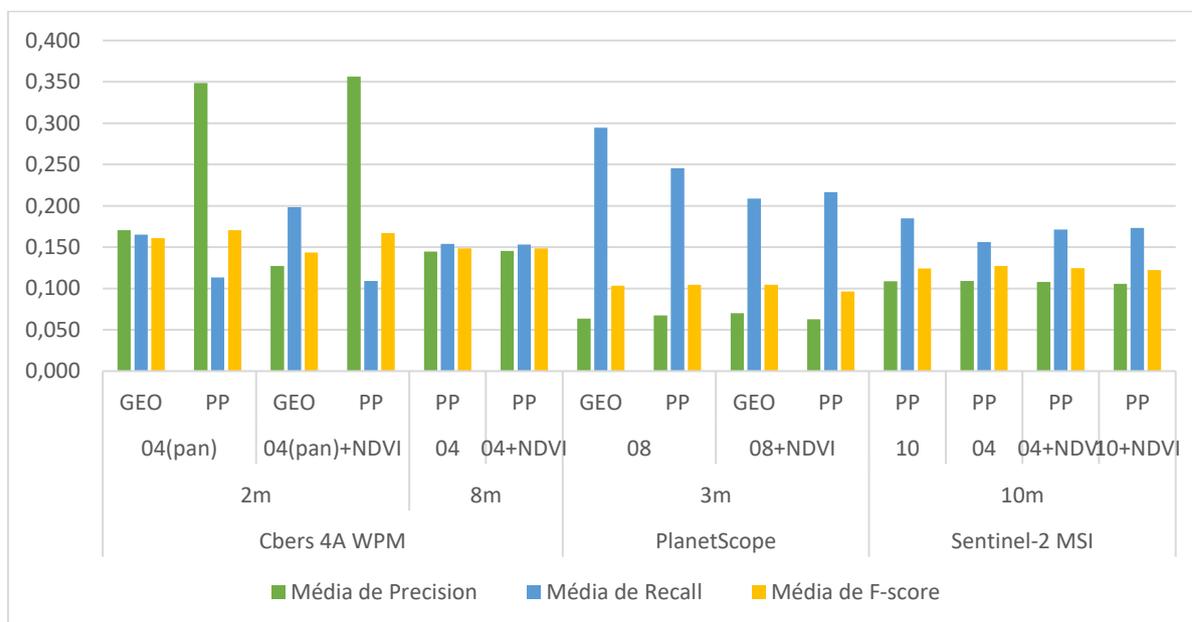


Figura 41. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC, agrupados por tipo de sensor, resolução espacial, bandas espectrais / NDVI e técnicas de mapeamento utilizadas.

Ao analisarmos os resultados médios das validações dos mapeamentos das clareiras florestais com base exclusivamente nos algoritmos utilizados, conforme ilustrado na Figura 42, observamos que as classificações realizadas com RF demonstraram o maior valor para a métrica Recall, além de terem apresentado um equilíbrio mais elevado entre Precisão e Recall, refletido em valores mais altos de F-score. O algoritmo K-NN se destacou por oferecer a melhor Precisão, embora tenha registrado o menor valor médio de Recall. O algoritmo SVM se posicionou de forma intermediária em relação aos resultados dos demais algoritmos utilizados.

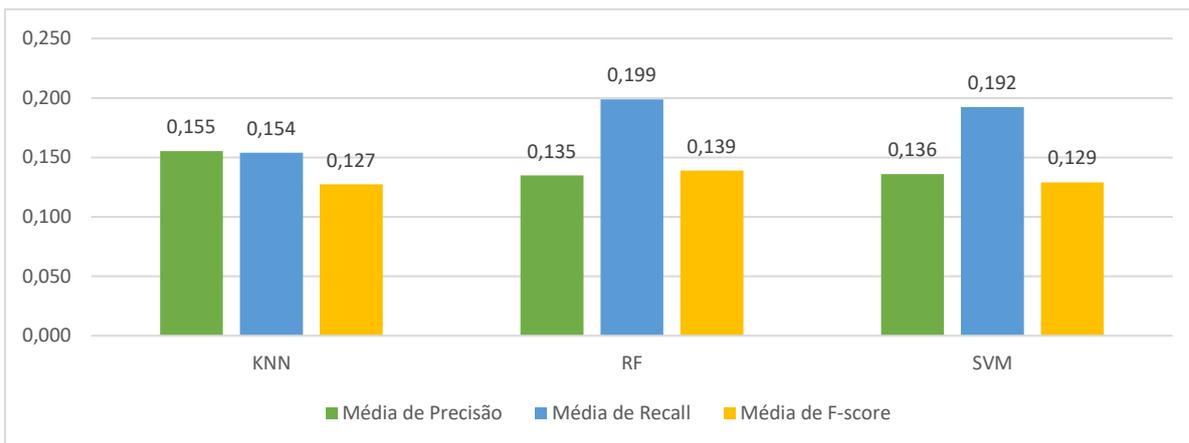


Figura 42. Valores médios das métricas de concordância para a classe clareira nos mapeamentos realizados com sensores ópticos na AC agrupados por tipo de algoritmo utilizado.

Conforme ilustrado na Figura 43, é crucial ressaltar a correlação significativa entre a extensão total das clareiras mapeadas e os resultados das validações com dados Lidar. Menores áreas de clareira mapeadas estão associadas a valores mais altos de Precisão, enquanto áreas mapeadas maiores se relacionam a valores mais elevados de Recall. Essa correlação é observada, por exemplo, no caso do algoritmo K-NN, que, em média, mapeou a menor área de clareiras, apresentando maior Precisão, mas o menor valor de Recall.

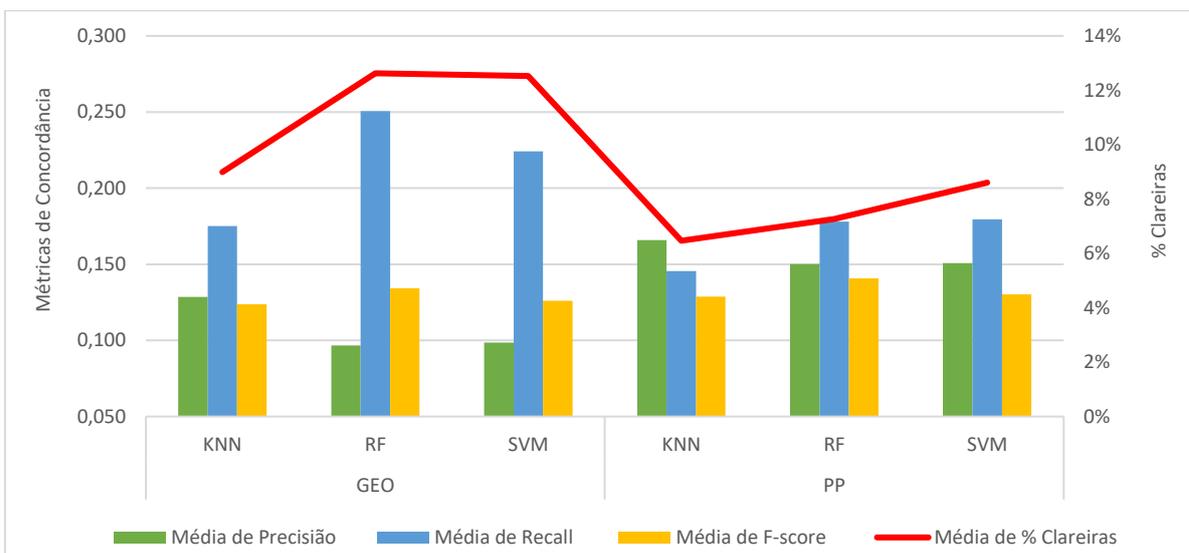


Figura 43. Valores médios das métricas de concordância para a classe clareira e percentual de abertura no dossel nos mapeamentos realizados com sensores ópticos na AC agrupados por tipo de algoritmo utilizado.

Como evidenciado na Figura 44, a variação dos resultados das métricas de concordância em função do tipo de algoritmo utilizado é considerada por nós como pequena. Em média, os valores de desvio padrão em relação ao tipo de algoritmo utilizado ficaram abaixo de 5% para Precisão e abaixo de 2% em F-score. Em Recall, onde foi verificada a maior variação dentre os resultados de cada conjunto de dados em função do tipo de algoritmo utilizado, o desvio padrão foi inferior a 9% em todos os conjuntos de dados utilizados.

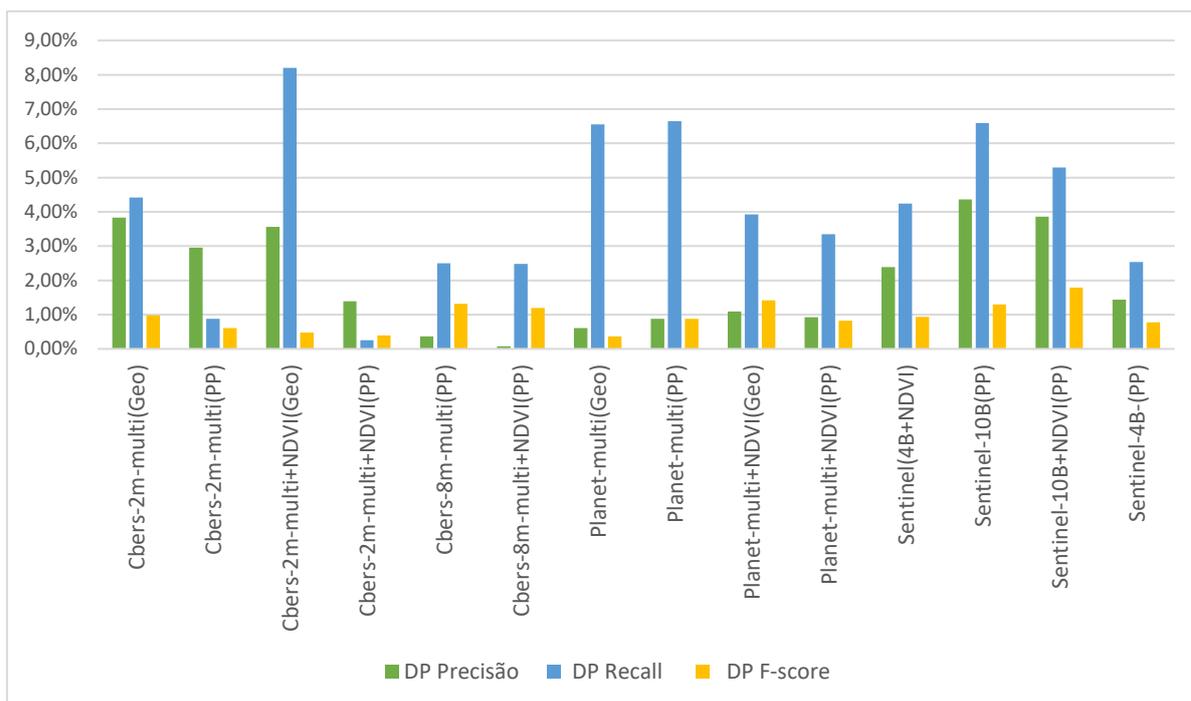


Figura 44. Valores percentuais dos desvios padrão dos resultados das métricas de concordância em função do tipo de algoritmo utilizado em cada conjunto de dados classificado.

Com o objetivo de validar o mapeamento das clareiras florestais associadas à presença de infraestruturas, foram selecionadas as aberturas no dossel, identificadas tanto por dados Lidar quanto por sensores ópticos, que se sobrepõem às estradas e pátios de estocagem instalados sobre a AC. A Tabela 14 apresenta os resultados médios das métricas de concordância nos mapeamentos de todas as clareiras, em comparação aos resultados obtidos nos mapeamentos restritos às clareiras sobrepostas à infraestrutura instalada em cada conjunto de dados classificados. Os dados estão organizados em ordem decrescente em relação aos resultados obtidos com a métrica F-score ao restringir o mapeamento às clareiras sobrepostas à infraestrutura.

A melhoria média nas três métricas de concordância utilizadas é superior a 130%, com ganhos superiores a 200% em alguns conjuntos de dados. Esses resultados são inequívocos nas três principais métricas de concordância utilizadas e evidenciam a maior eficácia dos sensores ópticos ao mapear clareiras relacionadas à infraestrutura em relação às clareiras de exploração.

Conforme evidenciado na Figura 45, de maneira geral, a hierarquia entre os conjuntos de dados em termos dos resultados para cada métrica de validação permaneceu inalterada ao classificar apenas as clareiras sobrepostas à infraestrutura. Isso significa que os conjuntos de dados que se destacaram em determinada métrica durante a validação dos mapeamentos de todas as clareiras continuaram a se sobressair nos mapeamentos exclusivos das clareiras

associadas à infraestrutura. É importante frisar que todas as classificações apresentaram consistentemente resultados superiores nos mapeamentos mais restritivos.

Conjunto de dados	Precisão	Precisão Infra	Ganho Precisão %	Recall	Recall Infra	Ganho Recall %	F-score	F-score Infra	Ganho F-score
Cbers-2m-multi+NDVI(PP)	0,356	0,654	83,54	0,109	0,290	165,16	0,167	0,401	140,14
Cbers-2m-multi(PP)	0,349	0,645	85,00	0,113	0,287	153,72	0,170	0,397	133,31
Cbers-2m-multi(Geo)	0,171	0,397	132,83	0,165	0,395	139,04	0,161	0,390	142,73
Cbers-8m-multi(PP)	0,145	0,431	197,88	0,154	0,351	128,11	0,148	0,386	159,81
Cbers-8m-multi+NDVI(PP)	0,145	0,416	185,80	0,153	0,349	128,05	0,148	0,378	154,88
Cbers-2m-multi+NDVI(Geo)	0,127	0,352	176,98	0,198	0,432	117,58	0,143	0,377	163,18
Sentinel-4B-(PP)	0,109	0,303	177,40	0,156	0,359	129,87	0,127	0,326	156,37
Planet-multi+NDVI(Geo)	0,070	0,269	283,08	0,209	0,396	89,83	0,104	0,318	204,86
Planet-multi+NDVI(PP)	0,063	0,214	240,93	0,216	0,435	101,12	0,096	0,285	195,86
Sentinel(4B+NDVI)	0,108	0,239	121,93	0,171	0,382	122,96	0,124	0,283	127,18
Planet-multi(PP)	0,067	0,210	211,72	0,246	0,457	86,24	0,104	0,281	169,92
Sentinel-10B+NDVI(PP)	0,106	0,214	103,06	0,173	0,385	122,41	0,122	0,266	117,90
Sentinel-10B(PP)	0,109	0,200	84,54	0,185	0,402	117,64	0,124	0,256	106,43
Planet-multi(Geo)	0,063	0,170	167,52	0,295	0,527	78,87	0,103	0,256	147,57
Média Geral	0,142	0,337	137,20	0,182	0,389	114,16	0,132	0,329	149,48

Tabela 14. Valores médios dos resultados das métricas de concordância nos mapeamentos de todas as clareiras, em comparação aos resultados dos mapeamentos das clareiras sobrepostas à infraestrutura instalada.

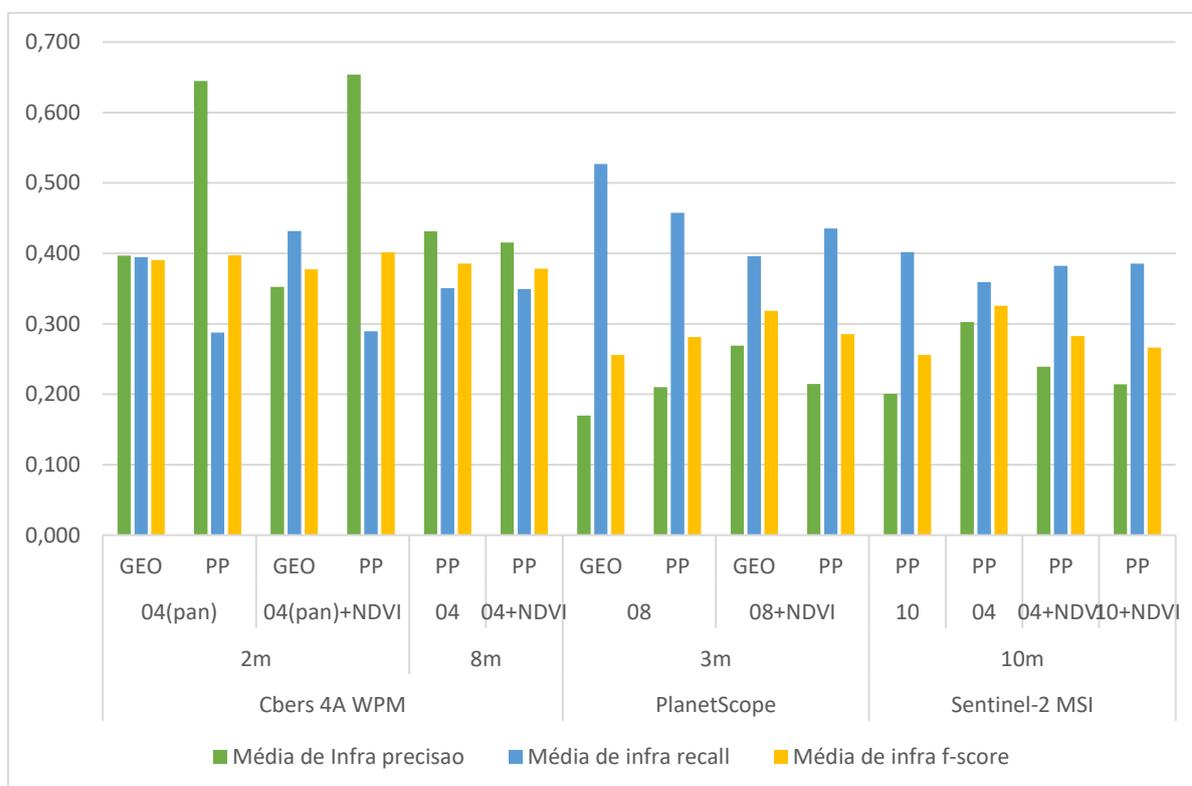


Figura 45. Valores médios das métricas de concordância nos mapeamentos das clareiras sobrepostas à infraestrutura. Dados agrupados por tipo de sensor, resolução espacial, bandas / NDVI e técnica de mapeamento adotada.

Conforme ilustrado nas Figura 46 e 48, observa-se que, em relação aos valores médios das métricas de Precisão e F-score, os ganhos mais expressivos foram evidenciados nos conjuntos de dados PlanetScope. Por outro lado, para a métrica Recall (Figura 47), os maiores ganhos ao restringir o mapeamento as clareiras sobrepostas à infraestrutura foram verificados com dados Cbers 4A WPM. É notável que os maiores incrementos foram observados nas métricas em que cada tipo de sensor apresentou piores resultados durante a validação dos mapeamentos abrangendo todas as clareiras.

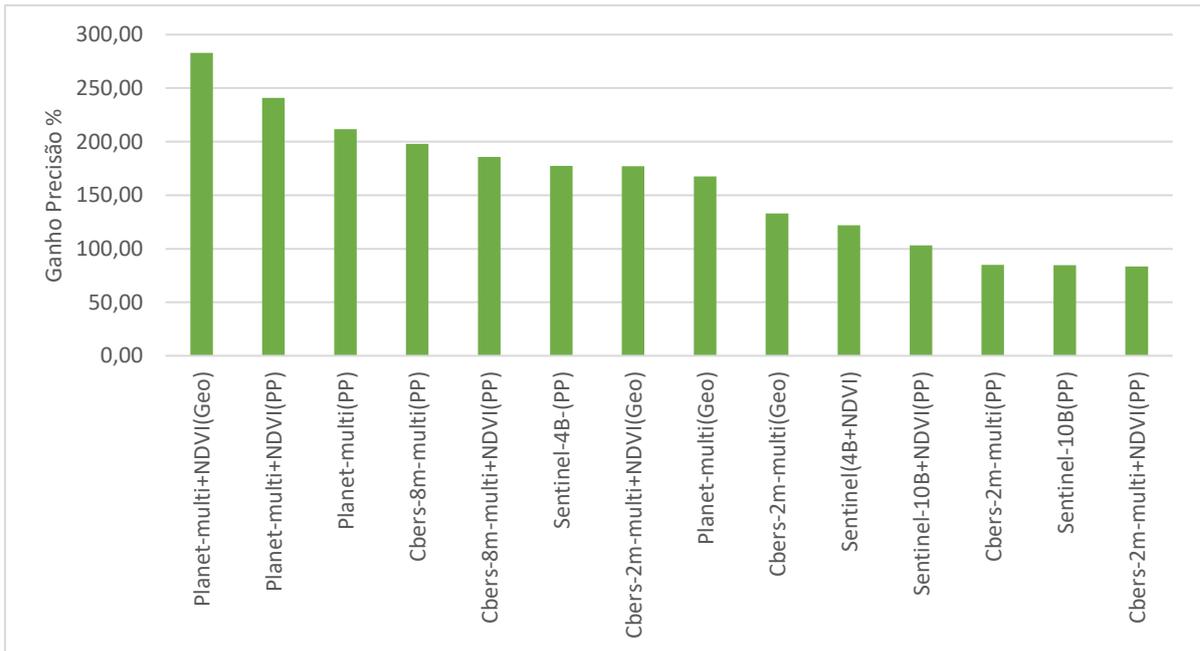


Figura 46. Valor médio do ganho em Precisão ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.

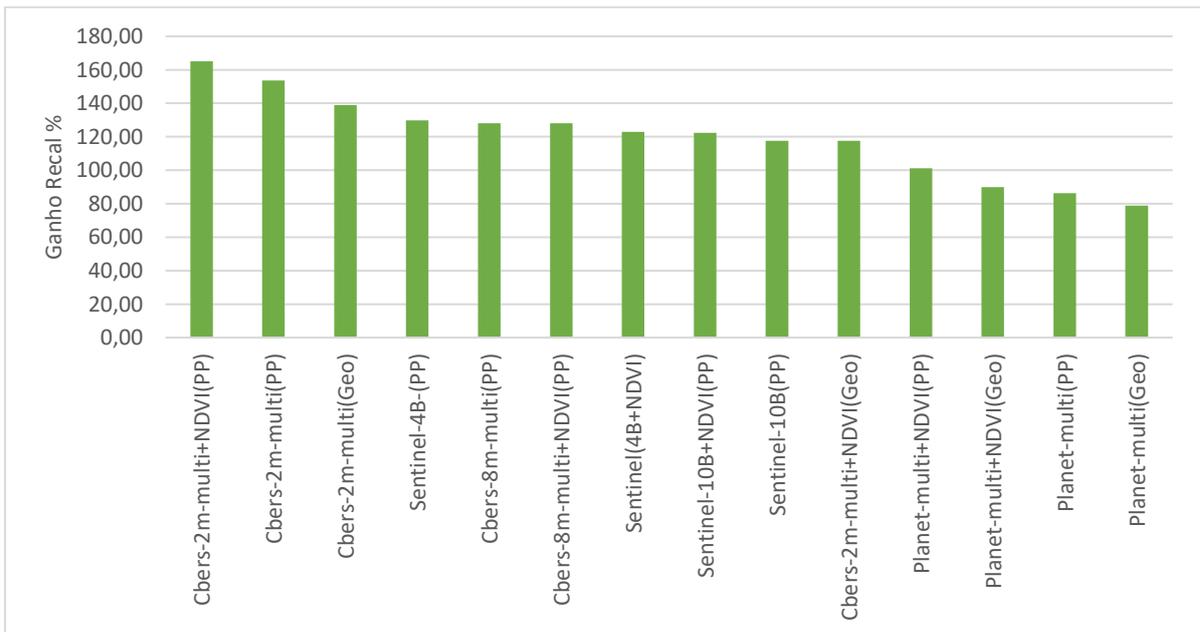


Figura 47. Valor médio do ganho em relação à métrica Recall ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.

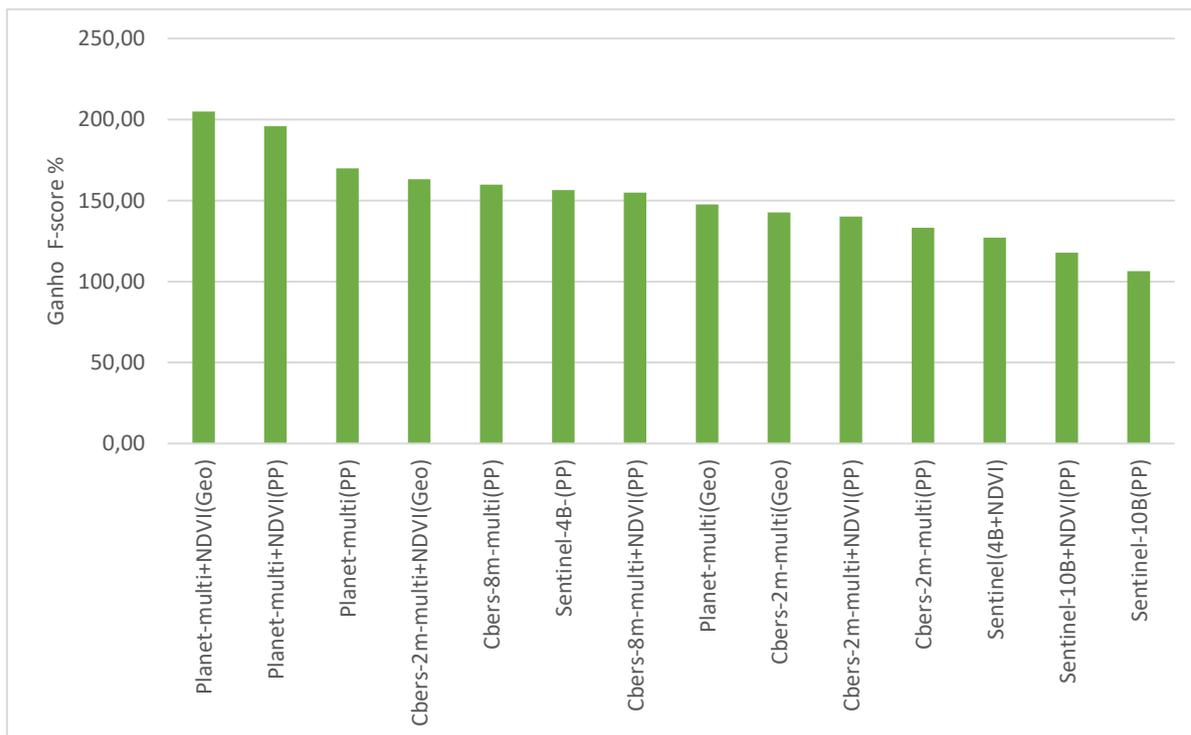


Figura 48. Valor médio do ganho em relação à métrica F-score ao restringirmos o mapeamento às clareiras sobrepostas a infraestrutura instalada.

Adicionalmente, as discrepâncias nos resultados das métricas de concordância entre os conjuntos de dados foram menos acentuadas nos mapeamentos realizado apenas com as clareiras associadas à infraestrutura. A diferença entre os conjuntos de dados que apresentaram, em média, os melhores e piores resultados em termos de Precisão reduziu de 465,1%, quando todas as clareiras foram consideradas, para 284,7% no mapeamento mais restritivo. Nessa mesma comparação, a variação dos resultados em relação às outras duas métricas diminuiu de 170,6% para 83,6% em Recall e de 77,01% para 39,3% em F-score.

Esses resultados refletem a realidade de campo, na medida em que as clareiras relacionadas à infraestrutura geralmente apresentam o solo exposto, tornando-as mais fáceis de serem reconhecidas pelos algoritmos de classificação devido à maior diferença em suas respostas espectrais em relação ao dossel florestal. Em contrapartida, nas clareiras de exploração, resultantes do impacto da copa das árvores abatidas para comercialização sobre a vegetação circundante, o solo não fica exposto, pois permanece coberto pela biomassa da copa da árvore derrubada, bem como pelos detritos resultantes do impacto sobre a vegetação circundante, tornando-os suas respostas espectrais mais semelhantes às do dossel florestal. Além disso, apresentam uma distribuição aleatória e com limites menos distintivos do que a infraestrutura.

8 DISCUSSÃO

Nossa revisão bibliográfica foi realizada principalmente nas plataformas online Web of Science e Google Scholar. No entanto, não conseguimos encontrar estudos nessas plataformas que explorassem o uso de imagens do sensor Cbers 4A WPM em análises relacionadas à supressão de vegetação. Segundo Veras (2022), a escassez de pesquisas científicas utilizando dados Cbers 4A WPM é notável tanto na literatura nacional quanto internacional. Uma das possíveis explicações para essa lacuna pode ser a falta de disponibilidade sistemática do catálogo de imagens para países além do Brasil, conforme apontado por Adorno (2023). Ademais, é importante destacar que o satélite possui um histórico de operação relativamente curto, com dados disponíveis a partir de 2020, e a resolução temporal do sensor WPM é relativamente baixa, o que dificulta a obtenção de imagens sem a interferência de nuvens, especialmente na região da Floresta Amazônica.

No entanto, Read (2003) conduziu uma análise visual utilizando imagens do sensor Ikonos, com uma resolução espacial de 4 metros para as bandas multiespectrais e 1 metro para a banda pancromática, o que é bastante próximo da resolução do sensor Cbers 4A WPM. O estudo de Read focou em analisar clareiras em áreas de MFS no estado do Amazonas. Assim como em nosso estudo, a autora observou uma maior distinção das estradas principais e pátios de estocagem em detrimento das estradas secundárias e clareiras menores, das quais apenas algumas puderam ser detectadas.

Em relação às imagens do PlanetScope, Stoll et al. (2021) utilizaram esses dados com uma resolução espacial de 3,7 m e a técnica Geobia para mapear áreas de mineração na Floresta Amazônica guianense. Os autores empregaram o algoritmo de segmentação LSMS e o algoritmo de classificação SVM. Eles obtiveram resultados de acurácia geral pelo método OOB variando entre 70% (para solo exposto) e 90% (para áreas sob mineração).

Masiliūnas (2017) utilizou imagens Sentinel-2 MSI para mapear áreas sob ESM em área de Floresta Amazônica na Guiana e verificou que 43% de todas as clareiras conhecidas puderam ser discernidas com confiança. O autor também verificou que só foi possível identificar as clareiras que apresentassem o solo exposto. Com base na análise de imagens Sentinel-2 MSI que abrangeu sete áreas sob MFS no sul do estado do Amazonas, Lima et al. (2019) observaram uma taxa de abertura do dossel florestal de 5,73%. Em nossos mapeamentos utilizando esse sensor, encontramos uma média da área total de clareiras em relação UPA 4D de 9,29%. No entanto, o percentual de abertura no dossel variou

consideravelmente entre as doze classificações realizadas com este sensor, variando de 4,44% (10 bandas, Pixel a Pixel, e K-NN) a 18,31% (10 bandas, Pixel a Pixel e SVM).

Silva (2014), em um estudo com imagens dos satélites GeoEye-1 e WorldView-2, com resoluções espaciais variando entre 0,41 m e 1,85 m, além de coleta de dados em campo na Flona de Jamari, estimou a abertura média do dossel florestal em cerca de 30%. Esse resultado é semelhante ao da classificação que mapeou o maior percentual de clareiras (29,95%) dentre as 42 classificações que realizamos. A área máxima que obtivemos foi utilizando o sensor PlanetScope com o método Geobia e o algoritmo SVM.

No mesmo estudo, Silva (2014) observou que as áreas ocupadas individualmente pelas clareiras variaram entre 84,38m² a 417m², com áreas médias na faixa de 215m², e o percentual de abertura no dossel variando entre 7,37% e 9,3%. Nos mapeamentos que realizamos com dados Lidar, a área média ocupada por cada clareira, considerando polígonos mínimos de 20 m², foi de 106,65 m², enquanto nos mapeamentos com áreas mínimas de 40 m², foi de 164 m². As clareiras com pelo menos 40 m² e sobrepostas à infraestrutura apresentaram uma área média de 579 m².

O estudo conduzido por Asner et al. (2004) em áreas sob MFS no estado do Pará, baseado em coleta de dados em campo, verificou que o percentual de abertura do dossel florestal foi de 8%. Uma pesquisa realizada por Matricardi & Locks (2019), utilizando dados Lidar em 21 UPAs distribuídas em três Flonas sob concessão florestal na Amazônia, estimou que, após a exploração madeireira, essas áreas apresentaram uma média de 7,8% de clareiras. Dalagnol et al. (2019), também empregando dados Lidar, obteve uma estimativa de 6,15% em termos de supressão do dossel em áreas sob MFS na Flona do Jamari.

Em nosso estudo, a média percentual da área de clareiras nas 42 classificações realizadas sobre a AC foi de 7,67%. Considerando que o percentual obtido nos mapeamentos com dados Lidar variou entre 4,08% e 4,57%, podemos observar que os mapeamentos realizados com sensores ópticos tendem a superestimar as áreas de clareiras em comparação com os mapeamentos com dados Lidar, em média, em mais de 65%. Todavia, em 17 das classificações que realizamos os percentuais de clareiras mapeadas ficou abaixo de 5%, sobretudo quando foram utilizados dados Cbers 4A WPM. De forma semelhante, em estudo desenvolvido por Monteiro (2005), o autor observou que a medição da largura das estradas em áreas sob MFS por meio de imagens Ikonos, com resolução espacial variando entre um e quatro metros, apresentou resultados superestimados em comparação às medidas realizadas em campo. Dalagnol et al. (2023), ao mapear a degradação florestal em escala regional no

estado do Mato Grosso utilizando imagens dos mosaicos Planet NICFI com resolução espacial de 4,77m e técnicas de Aprendizagem Profunda (Deep Learning), também observaram que a área de clareiras mapeada foi maior do que a área realmente perturbada, resultando na superestimação, em termos de área, das estradas.

Apesar das clareiras relacionadas a infraestrutura serem mais facilmente discerníveis com imagens de sensoriamento remoto, Asner et al. (2004) verificaram, por meio de medições em campo em áreas sob MFS no estado do Pará, que mais de dois terços da vegetação impactada pela atividade madeireira está relacionada a formação das clareiras de exploração, apesar de individualmente serem muito menores em comparação as clareiras associadas à infraestrutura. Em consonância, Pereira et al. (2002), também com base em dados coletados em campo no estado do Pará, verificaram que a principal fonte de abertura no dossel em áreas sob MFS são as clareiras de exploração. Por sua vez, Welsink et al. (2023), ao mapearem áreas sob concessão florestal no Congo utilizando o mosaico Planet com resolução espacial de 4,77m e dados do radar do satélite Sentinel-1, constataram que cerca de um terço da abertura no dossel florestal foi resultado da instalação de estradas. Esses resultados são compatíveis com o mapeamento que realizamos com dados Lidar, uma vez que observamos que cerca de um terço do total de clareiras mapeadas estava, mesmo que parcialmente, sobreposto à infraestrutura instalada.

Em relação à taxa de detecção da infraestrutura madeireira com sensores ópticos orbitais, no estudo realizado por Lima et al. (2019) utilizando imagens Sentinel-2 MSI, e validação em campo, foi obtido um resultado de 43,2% de detecção. Em uma pesquisa similar, Silva (2014) comparou os mapeamentos da infraestrutura realizados com imagens de altíssima resolução espacial com o mapeamento realizado com dados Lidar pelo SFB, constatando que 37,94% da extensão das estradas foi mapeada por meio da interpretação visual das imagens orbitais. Em nosso estudo, a taxa média de detecção das estradas principais e secundárias com o sensor Sentinel-2 MSI foi de 61,2% e 37,51%, respectivamente. Utilizando imagens do PlanetScope, as taxas médias foram de 72,73% e 50,19%, enquanto com o sensor Cbers 4A WPM, foram de 52,93% e 27,81%. Quanto à detecção de pátios de estocagem, o pior resultado que obtivemos em uma classificação foi de 98,28% com dados Cbers 4A WPM, que possuíam dois metros de resolução espacial e foram classificados por Geobia com o algoritmo K-NN.

A utilização do NDVI, ao ser incorporado com as demais bandas espectrais empilhadas nos conjuntos de dados, não contribuiu para melhorias gerais nos mapeamentos das clareiras florestais. Uma dificuldade enfrentada ao utilizar o NDVI é que as sombras, em geral,

apresentam valores semelhantes aos das clareiras florestais. Em nossa metodologia, devido à incerteza na classificação das áreas sombreadas, optamos por associá-las à mesma classe do dossel florestal, escolha que pode ter contribuído para resultados menos satisfatórios com a inclusão do NDVI.

No entanto, com base nos dados ópticos que empregamos, o NDVI demonstrou um bom contraste visual entre o dossel e as clareiras de infraestrutura. Utilizamos essa distinção como suporte na interpretação das imagens, facilitando a coleta das amostras de treinamento e validação para a classificação das imagens. A pesquisa realizada por Masiliūnas (2017) com imagens Sentinel na Guiana indicam que o NDVI foi considerado um bom indicador para a detecção de grandes clareiras com solo exposto. Todavia, o autor concluiu que o NDVI mostrou-se menos sensível a mudanças na estrutura florestal do que outros índices de vegetação testados (NDMI, NBR, EVI e MSAVI).

Em relação ao tipo de algoritmo de classificação baseado em aprendizagem de máquina utilizado, o RF demonstrou consistentemente os melhores resultados durante as validações das classificações em relação aos dados Lidar. O RF registrou, em média, os maiores valores para as métricas Recall e F-score. Esses resultados corroboram com os obtidos em Lawrence & Moran (2015), Khatami et al. (2016) ao realizar classificações Pixel a Pixel e por Li et al. (2016) ao utilizar Geobia, em todos os estudos o RF foi o que apresentou melhor desempenho dentre vários algoritmos de classificação de imagens testados. Em termos de equilíbrio entre Recall e Precisão, o RF destacou-se como o algoritmo mais eficiente, como indicado pelos resultados da métrica F-score.

O algoritmo K-NN foi o aquele que ofereceu a maior precisão média, embora estivesse associado a uma área de clareiras mapeadas menor. O melhor resultado médio do K-NN em termos de precisão, vai de encontro ao que expõe Khatami et al. (2016), ao afirmar que apesar de sua simplicidade, o K-NN pode superar classificadores mais complexos. No entanto, a utilização do K-NN resultou em tempos de processamento mais longos, devido à necessidade de empregar todo o conjunto de dados para a geração do modelo de classificação. Essa maior exigência de processamento não representou um problema significativo para nossa pesquisa, uma vez que estávamos lidando apenas com uma única UPA. Todavia, destaca-se que em algumas situações, como na classificação pixel a pixel dos dados Cbers 4A WPM com resolução espacial de dois metros, combinados com o NDVI, o tempo necessário para a classificação utilizando o algoritmo K-NN foi aproximadamente 7.000 vezes maior em

comparação com o tempo de processamento necessário para os algoritmos RF e SVM. Além disso, os valores de Recall obtidos com o K-NN foram consideravelmente inferiores.

O SVM, por sua vez, ocupou uma posição intermediária em relação aos demais algoritmos em termos de F-score, Recall e Precisão nas validações das classificações em relação aos dados Lidar. Em relação à área total de clareiras mapeadas, o SVM foi, em média, o algoritmo que resultou em áreas calculadas mais extensas. A diferença entre as áreas de clareiras calculadas com o SVM foi cerca de 35% maior em comparação com as classificações realizadas com K-NN e 10,6 % em relação ao RF.

Quanto à assinatura espectral das clareiras florestais, assim como constatado por Asner et al. (2005) em sua pesquisa com dados Landsat ETM+ nos estados do Pará, Mato Grosso e Rondônia, verificamos que a maior distinção espectral entre as clareiras e o dossel florestal ocorreu principalmente na faixa do espectro eletromagnético correspondente à cor vermelha. Esta observação foi feita com base nas amostras coletadas sobre a infraestrutura instalada para realizarmos as classificações das imagens.

A Figura 48 apresenta, em termos percentuais, o total de abertura no dossel aferido em média nos mapeamentos que realizamos, agrupados por tipo de sensor óptico, em comparação aos percentuais obtidos por outros estudos citados nesta pesquisa, à despeito das diferenças metodológicas, desenvolvidos em áreas sob MFS na Floresta Amazônica.

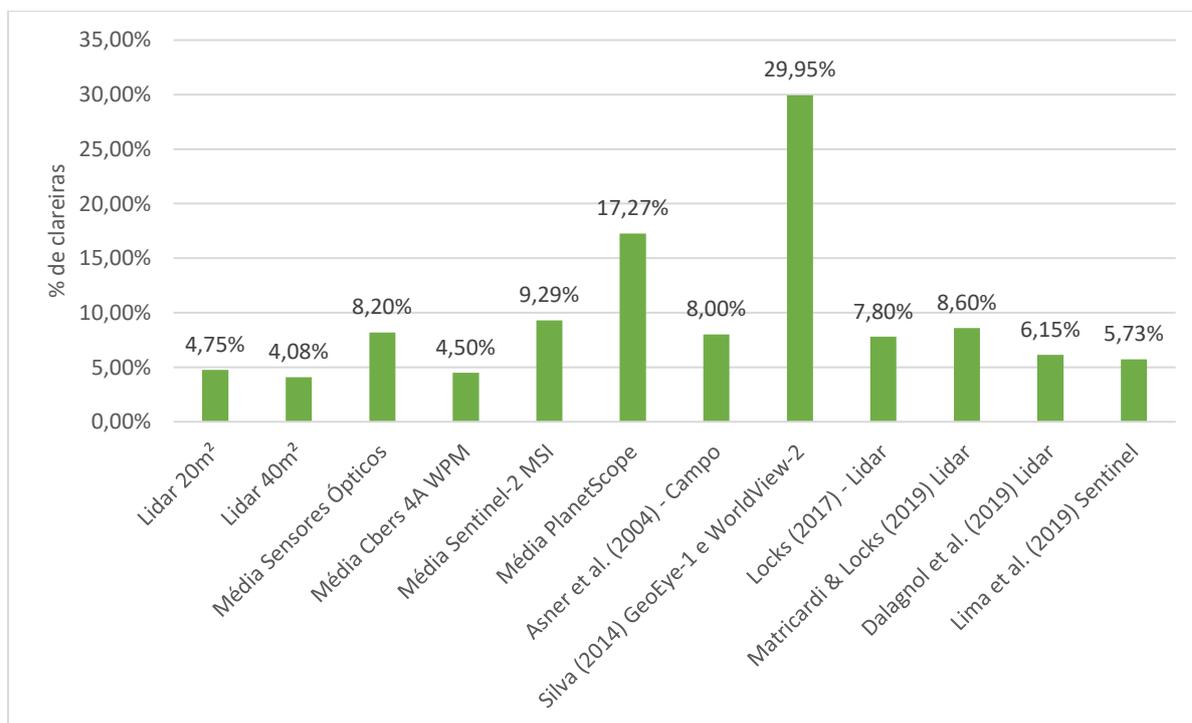


Figura 48. Percentual médio das áreas de clareiras mapeadas por unidade de área explorada agrupado por tipo de sensor óptico em comparação a outros estudos em áreas sob MFS na Floresta Amazônica.

Podemos concluir que as áreas de abertura no dossel que mapeamos com dados Lidar foram, em geral, inferiores aos obtidos em outras pesquisas, possivelmente devido ao menor limite de altura da vegetação que utilizamos para definição de clareiras. Por exemplo, Dalagnol et al. (2019) utilizou o limite de 10m. Em relação aos sensores ópticos, a taxa média de abertura no dossel que obtivemos nas 42 classificações realizadas apresentou resultados próximos aos obtidos pela maioria dos estudos mencionados na Figura 48.

9. CONCLUSÕES

A conservação da biodiversidade é fundamental para a sustentação da vida na Terra e está intrinsecamente ligada à forma como interagimos com as florestas globais. Idealmente, espera-se que as florestas geridas sob o conceito de MFS possam desempenhar um importante papel na conservação da biodiversidade, na mitigação das mudanças climáticas e no fornecimento de recursos essenciais. A implementação do MFS envolve trade-offs que necessitam de avaliação cuidadosa. Embora essa atividade diversifique as funções econômicas e reduza o risco de conversão da área para usos não florestais, ela, inevitavelmente, gera impactos sobre a biodiversidade. Todavia, deve-se ressaltar que a alteração no uso da terra decorrente do desenvolvimento de MFS não necessariamente representa a alteração na cobertura da terra.

Conforme a definição de floresta fechada estabelecida pela ITTO (BLASER et al., 2011), uma floresta é considerada fechada quando o dossel das árvores cobre 60% ou mais da superfície do solo quando visto de cima. De acordo com essa definição, os mapeamentos realizados com sensores ópticos nesta pesquisa indicam, em média, que cerca de 90% da UPA 4D permaneceu coberta pelo dossel florestal logo após o término da exploração florestal. Os mapeamentos com dados Lidar apontaram que aproximadamente 95% da área permaneceu coberta pelo dossel florestal.

O Estado brasileiro tem se comprometido com a rápida expansão da área de florestas públicas a serem concedidas à iniciativa privada para a realização de MFS (SFB, 2022b). Esse compromisso ressalta a necessidade de ampliação e aprimoramento das ferramentas de monitoramento por sensoriamento remoto, especialmente considerando sua eficiência econômica, dado que essas áreas frequentemente estão localizadas em regiões de difícil acesso, no interior da Floresta Amazônica. O mapeamento das clareiras florestais em áreas sob MFS utilizando sensores ópticos orbitais é crucial para diversos atores sociais, como empreendedores, agências públicas de controle, certificadoras e pesquisadores. Além disso, é

fundamental para a sociedade em geral, permitindo uma melhor compreensão dos impactos dessa atividade.

Apesar da importância dessas informações, nossa pesquisa revelou que as imagens provenientes dos sensores ópticos orbitais de maior resolução, amplamente disponíveis para instituições públicas e privadas no Brasil (Cbers 4A WPM, PlanetScope e Sentinel-2 MSI), quando utilizadas em classificações supervisionadas com o auxílio de algoritmos de aprendizado de máquina, apresentaram resultados relativamente abaixo do esperado. Os mapeamentos das clareiras realizados com esses sensores, em comparação com os resultados obtidos por meio de dados Lidar, tendem a superestimar as áreas de clareiras, em média, em mais de 65%. No entanto, houve uma melhoria significativa nos mapeamentos ao nos restringirmos às clareiras sobrepostas à infraestrutura instalada.

Todavia, é crucial ressaltar que os ambientes sob MFS são caracterizados por intrincados mosaicos de paisagens, nos quais as clareiras estão distribuídas de forma difusa. As informações dessas áreas são captadas pelos sensores ópticos, conforme afirmado por Monteiro (2005, p.24), "com grande ambiguidade espectral entre floresta explorada e não explorada". Portanto, essas áreas podem ser consideradas altamente complexas em termos de mapeamento por sensoriamento remoto em escala local. A notável disparidade entre os resultados obtidos, dependendo do sensor óptico e da técnica de mapeamento utilizada, ressalta a complexidade em mapear clareiras em áreas sob MFS.

A dificuldade em mapear os impactos do manejo florestal com os sensores ópticos utilizados é confirmada pelo cruzamento das clareiras mapeadas com dados Lidar associado à localização da infraestrutura instalada. Essa análise possibilitou constatar que, em mais da metade dos trechos das estradas secundárias, não ocorreu a descontinuidade do dossel florestal, tornando assim esses trechos da infraestrutura invisíveis aos sensores ópticos orbitais.

Com o objetivo de otimizar a classificação das imagens utilizadas, nossa abordagem representou uma tentativa desafiadora de mapear, individualmente, todas as clareiras, sejam elas naturais ou de origem antrópica, presentes na UPA 4D da UMF IV da Flona de Altamira logo após o término da atividade de exploração florestal. Para isso, combinamos diversas bandas espectrais, técnicas de mapeamento e algoritmos de aprendizagem, levando em consideração as características específicas de cada sensor, por meio de fusão de imagens, reamostragem de resolução e cálculo do NDVI.

A técnica Geobia não resultou em melhorias significativas na identificação de clareiras em nenhum dos sensores em que foi aplicada. Além disso, por ser um processo com mais etapas em comparação à técnica Pixel a Pixel, não recomendamos sua utilização, ao menos com os dados empregados neste estudo para o mapeamento de clareiras florestais.

Considerando as limitações das informações provenientes dos sensores ópticos utilizados, face aos desafios colocados em mapear as clareiras florestais, os ótimos resultados obtidos por meio da validação OOB indicam que os procedimentos que dependeram da interpretação humana foram realizados com correção. Além disso, o percentual de detecção da infraestrutura instalada foi considerado satisfatório.

Entendemos, conforme apontado por Jackson & Adam (2020), que a melhor fonte de dados e método escolhido para mapear ESM deve encontrar um equilíbrio entre precisão, custo dos dados e análises, e frequência ideal de monitoramento. No entanto, os impactos da exploração florestal variam amplamente, tornando a generalização, bem como a implementação de políticas, difícil.

Não é possível apontar um sensor ou conjunto de dados ópticos como possuidor de uma ampla supremacia sobre os demais. Contudo, notamos que os três sensores se complementam, e a utilização conjunta certamente aprimorará a análise sobre a distribuição das clareiras florestais em áreas sob MFS.

Os dados do PlanetScope oferecem uma vantagem significativa, pois estão disponíveis com resolução temporal diária, o que propicia uma maior possibilidade de obtenção de imagens sem nuvens, mesmo em períodos de maior nebulosidade. Além disso, possibilitam um monitoramento contínuo da distribuição espacial das clareiras durante a ESM. Os melhores resultados obtidos por esse sensor em relação à métrica Recall reforçam a vocação dessas imagens, especialmente em áreas sob MFS na Amazônia, para geração de alertas com indicativos da distribuição das clareiras e sua evolução espaço-temporal.

O sensor Cbers 4A WPM se destaca por sua alta resolução espacial e precisão superior, tornando-o mais adequado para análises detalhadas que exigem maior precisão quanto ao tamanho e formato das clareiras. Com uma resolução espacial de dois metros, é possível visualmente individualizar algumas árvores com copas dominantes no dossel florestal utilizando essas imagens. Além disso, trata-se de um produto desenvolvido em parte com tecnologia nacional e disponível gratuitamente. Dos três sensores ópticos utilizados, o sensor Cbers 4A WPM é o mais recomendado para a elaboração de mapas de campo para a realização de vistorias.

Os mapeamentos realizados com o sensor Sentinel-2 MSI revelaram, em geral, resultados intermediários entre os critérios avaliados. Dentre os sensores ópticos utilizados, o Sentinel-2 MSI é o mais prevalente em pesquisas científicas e foi amplamente testado em diversos tipos de paisagens terrestres. Destaca-se pela sua capacidade de mapeamento em escala local e regional. Neste contexto, entre os sensores ópticos testados, o Sentinel-2 MSI é o mais recomendado para análises ao nível da UMF.

Apesar dos resultados aquém das expectativas, não devemos subestimar a importância dos sensores Cbers 4A WPM, Sentinel-2 MSI e PlanetScope para o monitoramento e controle da atividade de MFS em concessões florestais federais. Essas imagens são importantes para a detecção das atividades de ESM, sobretudo por meio da análise visual de especialistas, apoiada por outros dados espaciais, como infraestrutura, canais de drenagem e inventários florestais georreferenciados com declaração de corte. Entretanto, não podemos considerar esses sensores como fontes acuradas para a medição de clareiras florestais individualmente.

Esta pesquisa pode contribuir para o aprimoramento dos mapeamentos de clareiras florestais em áreas sob MFS com a adoção de técnicas de EIR. Ademais, ela ressaltou as limitações inerentes aos sensores ópticos orbitais utilizados. A partir das análises apresentadas, torna-se evidente a necessidade premente da utilização de sensores com maior detalhamento espacial e espectral para aprimorar a eficácia do monitoramento ambiental por meio de sensoriamento remoto nas áreas sob MFS em concessões florestais federais.

Cabe ressaltar as principais dificuldades que restringiram o alcance deste estudo. A primeira delas foi a disponibilidade de imagens Cbers 4A WPM que atendessem aos seguintes critérios: ausência de cobertura de nuvens, captura da imagem após o término da exploração florestal e em uma data próxima aos aerolevantamentos realizados com dados Lidar. Essa foi a principal razão para restringirmos nosso estudo a apenas uma UPA. Devido à maior resolução temporal dos sensores PlanetScope e Sentinel-2 MSI, a disponibilidade de imagens que atendessem aos critérios estipulados não representou um problema para esses dados.

Uma outra importante limitação ocorreu devido à coleta de amostras referentes à classe de clareiras para o treinamento dos algoritmos de classificação, restritas às áreas sobrepostas à infraestrutura instalada. Essa abordagem foi adotada para garantir, dada a grande variabilidade espectral e o tamanho reduzido das clareiras em relação às resoluções espaciais utilizadas, que não fornecêssemos ao algoritmo de classificação amostras de clareiras que correspondessem, na realidade, ao dossel florestal não alterado. Reconhecemos que essa

opção conservadora possa ter limitado o aprendizado dos algoritmos e, conseqüentemente, a predição correta dos limites, principalmente das clareiras de exploração.

A utilização dos dados do Lidar aerotransportado confirmou os excelentes resultados encontrados na literatura científica para a medição da estrutura florestal. Essa tecnologia é considerada o "estado da arte" para a obtenção de métricas florestais e mapeamento da ESM com alta precisão. Os Modelos de Altura de Dossel gerados com os dados do Lidar proporcionam uma análise precisa das clareiras florestais, tornando-se extremamente úteis para agências ambientais no monitoramento e controle da atividade de MFS. Para estudos futuros, recomendamos a utilização do Modelo de Densidade Relativa (MDR), devido à sua capacidade de avaliar os impactos também sobre o sub-bosque florestal, além do dossel florestal. Dessa forma, possibilitam também o mapeamento das trilhas geradas pelos tratores durante o arraste das árvores abatidas para os pátios de estocagem.

Como recomendação para futuras pesquisas, sugerimos a realização de uma avaliação detalhada das assinaturas espectrais utilizando uma ampla variedade de sensores ópticos, tanto das clareiras resultantes da exploração, quanto das possíveis características que poderiam causar falsas detecções, como mudanças fenológicas e o envelhecimento das árvores com copas predominantes no dossel florestal. Acreditamos que isso permitirá uma delimitação mais precisa das assinaturas espectrais das clareiras, especialmente, às de exploração.

Recomendamos ainda a realização de estudos em outras áreas sob MFS para comparar os resultados em diferentes condições de vegetação, topografia e intensidade de exploração. Também sugerimos o desenvolvimento de testes com outros sensores ativos, como o Radar, além da aplicação de métodos de aprendizado de máquina profunda.

REFERÊNCIAS BIBLIOGRÁFICAS

ADORNO, B.; KÖRTING, T.; AMARAL, S. **Contribution of time-series data cubes to classify urban vegetation types by remote sensing**, *Urban Forestry & Urban Greening*, Volume 79, 2023, 127817, ISSN 1618-8667, <https://doi.org/10.1016/j.ufug.2022.127817>.

ALENCAR, A. et al. **Amazônia em Chamas - O Novo e Alarmante Patamar do Desmatamento na Amazônia**. Instituto de Pesquisa Ambiental da Amazônia 2022. Disponível em bit.ly/3Bn5ewU. Acesso em: 16 abr. 2022.

ALJUMAILY, H.; LAEFER, D.; CUADRA, D. **Integration of Lidar Data and GIS Data for Point Cloud Semantic Enrichment at the Point Level**. *Photogrammetric Engineering & Remote Sensing*, Vol. 85, No. 1, January 2019, pp. 29–42. © 2019 American Society for Photogrammetry and Remote Sensing, doi: 10.14358/PERS.85.1.29.

ALVARES, C. et al. **Köppen's Climate Classification Map for Brazil**. *Meteorologische Zeitschrift*. [2013]. doi: <http://dx.doi.org/10.1127/0941-2948/2013/0507>.

AQUINO, C. et al. **Using Experimental Sites in Tropical Forests to Test the Ability of Optical Remote Sensing to Detect Forest Degradation at 0.3 – 30 m resolutions**. *IGARSS 2021. IEEE International Geoscience and Remote Sensing Symposium*. pp. 677-680, doi: 10.1109/IGARSS47720.2021.9553389.

ASNER, G. P.; KELLER, M. and SILVA, J. N. M. **Spatial and Temporal Dynamics of Forest Canopy Gaps Following Selective Logging In the Eastern Amazon**. *Global Change Biology*, 10, 765–783 (2004). Disponível em <https://www.fs.usda.gov/research/treesearch/30194>. Acesso em: 13 nov. 2023.

_____. et al. **Selective Logging in the Brazilian Amazon**. In *Science* 21 october 2005 Vol 310. Publicado em 21/10/2005, *Science* 310, 480 (2005). doi:10.1126/science.1118051.

AZEVEDO-RAMOS, C.; SILVA, J.N.M.; e MERRY, F. **The evolution of Brazilian forest concessions**. *Elementa: Science of the Anthropocene* 1 January 2015; 3 000048. doi: <https://doi.org/10.12952/journal.elementa.000048>.

BAATZ M.; SCHÄPE, A. **Multiresolution Segmentation: an Optimization Approach for High Quality Multi-Scale Image Segmentation**. *Journal of Photogrammetry and Remote Sensing*, Heidelberg, v. 58, n. 3-4, p. 12-23. (2000).

BANCO NACIONAL DO DESENVOLVIMENTO ECONÔMICO E SOCIAL - BNDES. **Hub de Projetos**. [2023]. Disponível em <https://hubdeprojetos.bndes.gov.br/pt/setores/Florestas>. Acesso em: 28 set. 2023.

BECKER, B. **Geopolítica da Amazônia – A nova Fronteira de Recursos**. Ed. Zahar, Rio de Janeiro, 1982.

BELGIU, M. e DRĂGUȚ, L. **Random Forest in Remote Sensing: A Review of Applications and Future Directions**. ISPRS Journal of Photogrammetry and Remote Sensing 114: 24–31. (2016). Pages 24-31, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.

BLASCHKE, T.; Lang, S.; Lorup, E.; Strobl, J. and P. Zeil, **Object-Oriented Image Processing in an Integrated Gis/Remote Sensing Environment and Perspectives for Environmental Applications**, in Environmental Information Planning, Politics and the Public, 3rd ed, vol. 2. Berlin, Germany: Metropolis Verlag, 2000, pp. 555–570.

_____. **Object Based Image Analysis for Remote Sensing**. ISPRS Journal of Photogrammetry and Remote Sensing, Volume 65, Issue 1, 2009, Pages 2-16, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2009.06.004>.

BLASER, J. et al. **Status of Tropical Forest Management 2011**. ITTO Technical Series No 38. International Tropical Timber Organization, Yokohama, Japan (2011). Disponível em <https://www.itto.int/tfu/id=2686>. Acesso em 13 nov. 2023.

BONAN, G. B. **Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests**. Science. 2008 Jun 13;320(5882):1444-9. doi: 10.1126/science.1155121. PMID: 18556546.

BOZKURT, B. **An Object-Based Classification Approach to Identify Pumpkin and Pumpkin Flower Using UAV Imagery**. Geo-information Science and Remote Sensing. Thesis Report GIRS-2021-40, June 29th, 2021. Thesis submitted in partial fulfilment of the degree of Master of Science at Wageningen University and Research. Wageningen, The Netherlands. Disponível em https://webdosya.csb.gov.tr/db/cbs/icerikler/29062021_busrabozkurt_thes-sreport-20220602101201.pdf. Acesso em 04/01/2024.

BRASIL. Decreto Federal nº 89.817/1984. **Estabelece as Instruções Reguladoras das Normas Técnicas da Cartografia Nacional**. Disponível em https://www.planalto.gov.br/ccivil_03/decreto/1980-1989/d89817.htm#:~:text=D89817&text=DECRETO%20N%C2%BA%2089.817%2C%20DE%2020,Normas%20T%C3%A9cnicas%20da%20Cartografia%20Nacional.Acesso em 15/01/2024.

_____. Decreto Federal 2.483 de 1998. **Cria a Floresta Nacional de Altamira**. Disponível em https://www.planalto.gov.br/ccivil_03/decreto/D2483.htm#:~:text=DECRETO%20N%C2%BA%202.483%2C%20DE%202,vista%20o%20disposto%20no%20art. Acesso em: 13 nov. 2023.

_____. Lei Federal 9.985/2000. **Institui o Sistema Nacional de Unidades de Conservação da Natureza**. Disponível em http://www.planalto.gov.br/ccivil_03/leis/19985.htm. Acesso em: 13 nov. 2023.

_____. Lei Federal 11.284/2006. **Dispõe sobre a Gestão de Florestas Públicas para a Produção Sustentável.** Disponível em http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/111284.htm. Acesso em: 13 nov. 2023.

_____. Decreto Federal nº 5.975, de 30 de novembro de 2006 (2006b). **Regulamenta a Exploração de Florestas.** Disponível em http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/decreto/d5975.htm. Acesso em: 13 nov. 2023.

BREIMAN, L. Random Forests. **Machine Learning** 54 (1): 5–32. doi:10.1023/A:1010933404324. (2001).

BRIENEN, R.; PHILLIPS, O.; FELDPAUSCH, T. et al. **Long-Term Decline of the Amazon Carbon Sink.** *Nature* 519, 344–348 (2015). <https://doi.org/10.1038/nature14283>.

BROKAW, N. **The Definition of Treefall Gap and Its Effect on Measures of Forest Dynamics.** *Biotropica*, vol. 14, no. 2, 1982, pp. 158–60. JSTOR, <https://doi.org/10.2307/2387750>.

BUSTAMANTE, M. et al. **Toward an Integrated Monitoring Framework to Assess the Effects of Tropical Forest Degradation and Recovery on Carbon Stocks and Biodiversity.** *Glob Chang Biol.* 2016 Jan;22(1):92-109. doi: 10.1111/gcb.13087. Epub 2015 Nov 18.

CÁNOVAS, G. et al. **Modification of the Random Forest Algorithm to Avoid Statistical Dependence Problems When Classifying Remote Sensing Imagery.** *Computers & Geosciences* 103: 1–11. doi:10.1016/j.cageo.2017.02.012. (2017).

CARVALHO, W. et al. **Deforestation Control in the Brazilian Amazon: A Conservation Struggle Being Lost as Agreements and Regulations are Subverted and Bypassed,** *Perspectives in Ecology and Conservation*, Volume 17, Issue 3, 2019, Pages 122-130, ISSN 2530-0644, <https://doi.org/10.1016/j.pecon.2019.06.002>.

CHAN, J. C. W.; HUANG, C. and DEFRIES, R. 2001. **Enhanced Algorithm Performance for Land Cover Classification from Remotely Sensed Data Using Bagging and Boosting.** *IEEE Transactions on Geoscience and Remote Sensing Communications* 39 (3): 693–695. doi:10.1109/36.911126.

COMANICIU, D. and MEER, P. "**Mean Shift: a Robust Approach Toward Feature Space Analysis,**" in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 5, pp. 603-619, May 2002, doi: 10.1109/34.1000236.

CORTES, C.; VAPNIK, V. **Support-Vector Networks.** *Machine Learning* 20, 273–297 (1995). <https://doi.org/10.1007/BF00994018>.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas, SP: IG/UNICAMP, 1992.

DA SILVA, J.M.C., RYLANDS, A.B. and DA FONSECA, G.A.B. (2005), **The Fate of the Amazonian Areas of Endemism**. Conservation Biology, 19: 689-694. <https://doi.org/10.1111/j.1523-1739.2005.00705>.

DALAGNOL, R. et al. **Quantifying Canopy Tree Loss and Gap Recovery in Tropical Forests under Low-Intensity Logging Using VHR Satellite Imagery and Airborne Lidar**. Remote Sensing. 2019, 11, 817. <https://doi.org/10.3390/rs11070817>.

DE CARVALHO, A. L. et al. **Natural regeneration of trees in selectively logged forest in western Amazonia**. Forest Ecology and Management, Volume 392, 2017, Pages 36-44, ISSN 0378-1127, <https://doi.org/10.1016/j.foreco.2017.02.049>.

D'OLIVEIRA, M. V. N. et. al. **Estimating Forest Biomass and Identifying Low-Intensity Logging Areas Using Airborne Scanning Lidar in Antimary State Forest, Acre State, Western Brazilian Amazon**. Remote Sensing of Environment, Volume 124, 2012, Pages 479-491, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2012.05.014>.

DE LUCA, G.; SILVA, J.M.; CERASOLI, S.; ARAÚJO, J.; CAMPOS, J.; DI FAZIO, S.; MODICA, G. **Object-Based Land Cover Classification of Cork Oak Woodlands using UAV Imagery and Orfeo ToolBox**. Remote Sens. 2019, 11, 1238. <https://doi.org/10.3390/rs11101238>.

DE OLIVEIRA, J. **Identificação de danos ambientais em áreas das microrregiões do Jalapão e Barreiras, na região do Matopiba**. Trabalho de conclusão no curso de Engenharia de Agrimensura e Cartográfica, Universidade Federal de Uberlândia, campus Monte Carmelo, 2023. Disponível em <https://repositorio.ufu.br/bitstream/123456789/38152/1/Identifica%C3%A7%C3%A3oDanoAmbientais.pdf>. Acesso em 14/01/2024.

DE SOUZA, G. **Agricultura de Precisão por Sensoriamento Remoto: Estudo Aplicado na Fertirrigação de Cana-de-açúcar**. Tese apresentada ao Programa de Pós Graduação em Geografia da Universidade Federal de Minas Gerais. Orientadora: Profa. Dra. Ana Clara Mourão Moura, Belo Horizonte, 2022.

DE SOUZA, M. et al. **Validação da Acurácia Posicional de Imagens Cbers-4a e Planet Scope Usando Alvos Urbanos**. Revista Tamoios, São Gonçalo, v.19 ,n. 1, p. 207-222, 2023. Disponível em: 10.12957/tamoios.2023.61140. Acesso em: 07/11/2023.

DOS SANTOS, B.D.; de PINHO, C.M.D.; OLIVEIRA, G.E.T.; KORTING, T.S.; ESCADA, M.I.S.; AMARAL, S. **Identifying Precarious Settlements and Urban Fabric Typologies Based on GEOBIA and Data Mining in Brazilian Amazon Cities**. Remote Sens. 2022, 14, 704. <https://doi.org/10.3390/rs14030704>.

DUARTE, A.; ACEVEDO-MUÑOZ, L.; GONÇALVES, C.I.; Mota, L.; SARMENTO, A.; SILVA, M.; FABRES, S.; BORRALHO, N.; VALENTE, C. **Detection of Longhorned Borer Attack and Assessment in Eucalyptus Plantations Using UAV Imagery**. *Remote Sens.* 2020, 12, 3153. <https://doi.org/10.3390/rs12193153>.

DYKSTRA, D. P.; HEINRICH, R. Model Code of Forest Harvesting Practice. **Food and Agriculture Organization of the United Nations**, Rome, Italy. (1996). Disponível em <https://www.fao.org/3/v6530e/v6530e00.htm>. Acesso em: 06 out. 2022.

EICHERT, S.; ŠTULAR, B.; LOZÍČ, E. **Open Lidar Toolbox** - Tools for Lidar Data Preparation and Analysis in Archaeology. Versão 2.2.1 (2022). Disponível em https://plugins.Qgis.org/plugins/open_Lidar_tools/. Acesso em: 01 fev. 2023.

EINZMANN, K.; IMMITZER, M.; BÖCK, S.; BAUER, O.; SCHMITT, A.; ATZBERGER, C. WINDTHROW. **Detection in European Forests with Very High-Resolution Optical Data**. *Forests* 2017, 8, 21. <https://doi.org/10.3390/f8010021>

ELLIS, P. et al. **Mapping Selective Logging Impacts in Borneo with GPS and airborne Lidar** *Forest Ecology and Management*, Volume 365, 2016, Pages 184-196, ISSN 0378-1127, <https://doi.org/10.1016/j.foreco.2016.01.020>.

_____. et al. **Reduced-impact logging for Climate Change Mitigation (RIL-C) Can Halve Selective Logging Emissions from Tropical Forests**, *Forest Ecology and Management*, Volume 438, 2019, Pages 255-266, ISSN 0378-1127, <https://doi.org/10.1016/j.foreco.2019.02.004>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **O Novo Mapa de solos do Brasil** – Legenda Atualizada. (2011). Escala 1:5.000.000. Disponível em http://geoinfo.cnps.embrapa.br/layers/geonode%3ABrasil_solos_5m_20201104. Acesso em: 05 jan. 2023.

EUROPEAN SPACE AGENCY - ESA. **Sentinel-2 - User Guides** (2023). Disponível em <https://sentinel.esa.int/web/sentinel/user-guides/>. Acesso em: 06 fev. 2023.

FEARNSIDE, P. M. 2008. **The roles and Movements of Actors in the Deforestation of Brazilian Amazonia**. *Ecology and Society* 13(1): 23. [online] URL: <http://www.ecologyandsociety.org/vol13/iss1/art23/>.

FERREIRA, J. et al. **Degradação Florestal na Amazônia: Como Ultrapassar os Limites Conceituais, Científicos e Técnicos Para mudar Esse Cenário; Documentos 413 - Embrapa Amazônia Oriental**: Belém, Brazil, 2015. ISSN 1983-0513. Disponível em <https://agritrop.cirad.fr/584420/1/DOC413.pdf>. Acesso em: 04 out. 2022.

FODEN, W.B. et al. **Identifying the World's Most Climate Change Vulnerable Species: A Systematic Trait-Based Assessment of all Birds, Amphibians and Corals.** Plos One 8(6) [2013]: <https://doi.org/10.1371/journal.pone.0065427>.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **Global Forest Resources Assessment (2020):** Main report. Rome. <https://doi.org/10.4060/ca9825en>.

_____.; UNITED NATIONS ENVIRONMENT PROGRAMME. **The State of the World's Forests 2020. Forests, biodiversity and people.** Rome. <https://doi.org/10.4060/ca8642en>.

FRANCINI, S. et al. (2020) **Near-Real Time Forest Change Detection Using Planetscope Imagery,** European Journal of Remote Sensing, 53:1, 233-244, DOI: 10.1080/22797254.2020.1806734

FRANKE. J. et al. **Monitoring Fire and Selective Logging Activities in Tropical Peat Swamp Forests,** in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 5, no. 6, pp. 1811-1820, Dec. 2012, doi: 10.1109/JSTARS.2012.2202638.

FRIEDL, M. A.; BRODLEY, C. E. **Decision Tree Classification of Land Cover From Remotely Sensed Data,** Remote Sensing of Environment, Volume 61, Issue 3, 1997, Pages 399-409, ISSN 0034-4257, [https://doi.org/10.1016/S0034-4257\(97\)00049-7](https://doi.org/10.1016/S0034-4257(97)00049-7).

FUKUNAGA, K. and HOSTETLER, L. "**The estimation of the gradient of a density function, with applications in pattern recognition,**" in IEEE Transactions on Information Theory, vol. 21, no. 1, pp. 32-40, January 1975, doi: 10.1109/TIT.1975.1055330.

GAO, Y. et al. **A. Remote Sensing of Forest Degradation: a Review.** Environ. Res. Lett. 2020. doi 10.1088/1748-9326/abaad7. Acesso em: 12 nov. 2023.

GATTI, L. et al. **Drought Sensitivity of Amazonian Carbon Balance Revealed by Atmospheric Measurements.** Nature 506, 76–80 (2014). <https://doi.org/10.1038/nature12957>.

GHIMIRE, P.; LEI, D; JUAN.; N. **Effect of Image Fusion on Vegetation Index Quality—A Comparative Study from Gaofen-1, Gaofen-2, Gaofen-4, Landsat-8 OLI and MODIS Imagery.** Remote Sensing. 2020; 12(10):1550. <https://doi.org/10.3390/rs12101550>

GIONGO, M. et al. **Lidar: Princípios e Aplicações Florestais.** Pesquisa Florestal Brasileira, [S. 1.], v. 30, n. 63, p. 231, 2010. Disponível em <https://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/view/148>. Acesso em: 22 abr. 2022.

GONÇALVES, J. et al. **SegOptim—A new R package for optimizing object-based image analyses of high-spatial resolution remotely-sensed data**, International Journal of Applied Earth Observation and Geoinformation, Volume 76, 2019, Pages 218-230, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2018.11.011>

GRIZONNET, M. et al. **Orfeo Toolbox: Open Source Processing of Remote Sensing Images**. Open Geospat. Data Softw. Stand. 2017, 2, 15. Disponível em <https://www.orfeo-toolbox.org/CookBook/Installation.html>. Acesso em: 01 fev. 2023.

GROOMBRIDGE, B.; JENKINS, M. D. (2003) **World Atlas of Biodiversity**. Earth's Living Resources In The 21st Century. University of California Press, Berkeley, California, USA. Disponível em <https://www.international-food-safety.com/pdf/World%20Atlas%20Of%20Biodiversity.pdf>. Acesso em: 12 nov. 2023.

HAO, S.; CUI, Y.; WANG, J. **Segmentation Scale Effect Analysis in the Object-Oriented Method of High-Spatial-Resolution Image Classification**. Sensors 2021, 21, 7935. <https://doi.org/10.3390/s21237935>

HAY, G. J. and CASTILLA, G. Geographic Object-Based Image Analysis (Geobia): A New Name for a New Discipline. In **Object-Based Image Analysis**. Blaschke, T.; Lang, S.; Hay, G. Eds. Springer: Berlin/Heidelberg, Germany; New York, NY, USA, 2008; pp. 75–89 (2008).

HERNÁNDEZ-GÓMEZ, I. U. et al. **Assessment of the CLASlite Forest Monitoring System in Detecting Disturbance From Selective Logging in the Selva Maya, Mexico**. [2019]. Silva Fennica vol. 53 no. 1 article id 10012. <https://doi.org/10.14214/sf.10012>.

HEROLD, M. et al. **Options for monitoring and estimating historical carbon emissions from forest degradation in the context of REDD+**. Carbon Balance Manage 6, 13 (2011). <https://doi.org/10.1186/1750-0680-6-13>.

HETHCOAT, M. G. et al. **A Machine Learning Approach to Map Tropical Selective Logging**. Remote Sensing of Environment, Volume 221, 2019, Pages 569-582, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2018.11.044>.

HOARE, A. 2015. **Tackling Illegal Logging and the Related Trade: What Progress and Where Next? Chatham House Report**. London, Chatham House, The Royal Institute of International Affairs. Disponível em <https://www.chathamhouse.org/2015/07/tackling-illegal-logging-and-related-trade-what-progress-and-where-next>. Acesso em: 04 mar. 2023.

HOLMES, T. P. et al. **Custos e Benefícios Financeiros da Exploração de Impacto Reduzido em Comparação à Exploração Florestal convencional na Amazônia Oriental**, Belém: Fundação Floresta Tropical, 2004, 66p., 2ª edição. Disponível em http://ift.org.br/wp-content/uploads/2015/05/Holmes_Custos_Beneficios_2002.pdf. Acesso em: 13 nov. 2023.

HUNTER, M. O. et al. **Structural Dynamics of Tropical Moist Forest Gaps**. [2015]. Plos One 10(7): e0132144. doi:10.1371/journal.pone.0132144.

IBM. Random Forest. **IBM Cloud Learn Hub**. Disponível em <https://www.ibm.com/cloud/learn/random-forest>. Acesso em: 07 set. 2022.

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. **First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe**. Remote Sens. 2016, 8, 166. <https://doi.org/10.3390/rs8030166>

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA. Norma de Execução nº 1 de 18/12/2006. **Metodologia e Modelo de Relatório de Vistoria com a Finalidade de Subsidiar a Análise dos Planos de Manejo Florestal Sustentável**. Disponível em http://www.ibama.gov.br/phocadownload/biodiversidade/normas_execucao_manejo_florestal_01-2006_01e02-2007.pdf. Acesso em: 01 nov. 2022.

_____. Norma de Execução nº 1 de 24/04/2007. **Institui as Diretrizes Técnicas para Elaboração dos Planos de Manejo Florestal Sustentável**. Disponível em <https://www.ibama.gov.br/component/legislacao/?view=legislacoes&ano=2007&norma=106>. Acesso em: 24 abr. 2022.

_____. Instrução Normativa nº 21/2014. **Institui o Sistema Nacional de Controle da Origem dos Produtos Florestais**. Disponível em <https://www.ibama.gov.br/phocadownload/sinaflor/2018/2018-06-13-Ibama-IN-IBAMA-21-24-12-2014-SINAFLOR-DOF-compilada.pdf>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Introdução ao Processamento Digital de Imagens**. Manual Técnico em Geociências. Rio de Janeiro, 2001. Disponível em <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=281559>. Acesso em 24/12/2023.

_____. **Mapa Geomorfológico do estado do Pará**. Escala 1:250.000. Coordenação de Recursos Naturais e Estudos Ambientais. 1ª edição, 2006ª.

_____. **Manual Técnico da Vegetação Brasileira**. Coordenação de Recursos Naturais e Estudos Ambientais. Rio de Janeiro, 2012. Disponível em <https://biblioteca.ibge.gov.br/visualizacao/livros/liv63011.pdf>. Acesso em: 05 jan. 2023.

_____. **Mapa de Vegetação do Brasil**. Escala 1:250.000 (2021). Dados vetoriais disponíveis em https://geofp.ibge.gov.br/informacoes_ambientais/vegetacao/vetores/escala_250_mil/versao_2021/. Acesso em 27/11/2023.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE - ICMBio. **Plano de Manejo da Floresta Nacional de Altamira**. Volume I Brasília/DF (2012). Disponível em https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/amazonia/lista-de-ucs/flona-de-altamira/copy_of_pm_flona_altamira_vol.pdf. Acesso em: 02 jan. 2023.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Classificação de Imagens, Manual Spring**. [2006]. Disponível em <http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html>. Acesso em: 24 fev. 2023.

_____. **Degrad. Mapeamento da Degradação Florestal na Amazônia Brasileira, 2017**. Disponível em <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/degrad>. Acesso em: 14 mar. 2023.

_____. **Câmeras Imageadoras CBERS 04A**, [2019]. Disponível em <http://www.cbers.inpe.br/sobre/cameras/cbers04a.php>. Acesso em: 06 fev. 2023.

_____. **Níveis de Processamento das Imagens dos Satélites Cbers e Amazonia**, [2021]. Disponível em <http://www.dgi.inpe.br/documentacao/arquivos/NiveisdeProcessamentoCBERSAMZ.pdf>. Acesso em: 06 fev. 2023.

_____. Prodes. **O Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite**, 2022a. Disponível em <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Acesso em: 02 jan. 2023.

_____. **Metodologia Utilizada nos Sistemas Prodes e Deter** - 2a edição, 2022b. Disponível em <http://urlib.net/8JMKD3MGP3W34T/47GAF6S>. Acesso em: 12 out. 2022.

_____. **Apresentação Interativa dos Dados do Prodes até 2021**. Disponível em <http://www.dpi.inpe.br/prodesdigital/prodesmunicipal.php> (2022c). Acesso em: 20 dez. 2022

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate Change and Land: an IPCC Special Report on Climate Change, Desertification, Land Degradation, Sustainable Land Management, Food Security, and Greenhouse Gas Fluxes in Terrestrial Ecosystems** [2019].

ITTO - The International Tropical Timber Organization. **Voluntary Guidelines for the Sustainable Management of Natural Tropical Forests**. Policy Development Series No. 20. Yokohama, Japan (2015). Disponível em <https://www.itto.int/files/user/pdf/PR%20and%20Communications%20material/ITTO%20Voluntary%20Guidelines%20BROCHURE%20Web.pdf?v=1414133105>. Acesso em: 12 nov. 2023.

JACKSON, C. & ADAM, E. **Remote Sensing of Selective Logging in Tropical Forests: Current State and Future Directions**. *IForest* 13 286–300. (2020). doi: 10.3832/ifor3301-013.

JENSEN, J.R. **Sensoriamento Remoto do Ambiente: uma Perspectiva em Recursos Terrestres** (Tradução Da Segunda Edição). *Inf. Syst.* 2009, 598.

JOHNS, S. J.; BARRETO, P. and UHL, C. **Logging Damage During Planned and Unplanned Logging Operations In the Eastern Amazon**. *Forest Ecology and Management*, 89: 59–77 (1996). ISSN 0378-1127, [https://doi.org/10.1016/S0378-1127\(96\)03869-8](https://doi.org/10.1016/S0378-1127(96)03869-8).

JOHNSON, B. A. & MA, L. **Image Segmentation and Object-Based Image Analysis for Environmental Monitoring: Recent Areas of Interest, Researchers' Views on the Future Priorities**. *Remote Sensing*. 2020; 12(11):1772. <https://doi.org/10.3390/rs12111772>.

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S. V.; **A Meta-Analysis of Remote Sensing Research on Supervised Pixel-Based Land-Cover Image Classification Processes: General Guidelines for Practitioners and Future Research**, *Remote Sensing of Environment*, Volume 177, 2016, Pages 89-100, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2016.02.028>.

KHOSRAVIPOUR, A. et al. **Generating Pit-free Canopy Height Models from Airborne Lidar**. *Photogrammetric Engineering & Remote Sensing*, Vol. 80, No. 9, September 2014, pp. 863–872. © 2014 American Society for Photogrammetry and Remote Sensing, doi: 10.14358/PERS.80.9.863.

KILLEEN, J; JAUPI, L.; BARRETT, B. **Impact Assessment of Humanitarian Demining Using Object-Based Peri-Urban Land Cover Classification and Morphological Building Detection From VHR Worldview Imagery**, *Remote Sensing Applications: Society and Environment*, Volume 27, 2022, 100766, ISSN 2352-9385, <https://doi.org/10.1016/j.rsase.2022.100766>.

KOETZ, B. et al. **Fusion of imaging spectrometer and LIDAR data over combined radiative transfer models for forest canopy characterization**, *Remote Sensing of Environment*, Volume 106, Issue 4, 2007, Pages 449-459, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2006.09.013>.

KOTARIDIS, I. and LAZARIDOU, M. **Remote Sensing Image Segmentation Advances: a Meta-Analysis**, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 173, 2021, Pages 309-322, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2021.01.020>.

LANGNER, A.; JUKKA, M. and STIBIG, H. **Monitoring Forest Degradation for a Case Study in Cambodia: Comparison of Landsat 8 and Sentinel-2 Imagery**. Living Planet Symposium, Proceedings of the conference 9-13 May 2016 in Prague, Czech Republic. Edited by L. Ouwehand. ESA-SP Volume 740, ISBN: 978-92-9221-305-3, p.200. Disponível em <https://articles.adsabs.harvard.edu/pdf/2016ESASP.740E.200L>. Acesso em: 13 nov. 2023.

LAGO, G. et al. **Análise do Uso e Cobertura da Terra em Área de Preservação Permanente na Sub-Bacia do Córrego Campestre, Município de Campestre/MG**. Revista Eletrônica da Associação dos Geógrafos Brasileiros Seção Três Lagoas - V. 1, Nº 34, 2021.

LARY, D. et al. **Machine Learning in Geosciences and Remote Sensing**. Geoscience Frontiers. . Volume 7, Issue 1, 2016, Pages 3-10, ISSN 1674-9871, <https://doi.org/10.1016/j.gsf.2015.07.003>.

LAWRENCE, R. L. and MORAN, C. J. **The America View Classification Methods Accuracy Project: A Rigorous Approach for Model Selection**. Remote Sensing of Environment, 170: 115–120. doi:10.1016/j.rse.2015.09.008. [2015].

LEITOLD, V., KELLER, M., MORTON, D.C. et al. **Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+**. Carbon Balance Manage 10, 3 (2015). <https://doi.org/10.1186/s13021-015-0013-x>

LI, M. et al. **A Systematic Comparison of Different Object-Based Classification Techniques Using High Spatial Resolution Imagery**. In Agricultural Environments. International Journal of Applied Earth Observation and Geoinformation, Volume 49, 2016, Pages 87-98, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2016.01.011>.

LIU, Y.; LI, Y.; LI, S. and MOTESHARREI, S. **Spatial and Temporal Patterns of Global NDVI Trends: Correlations with Climate and Human Factors** (2015). Remote Sens., 7, 13233–13250, doi:10.3390/rs71013233

LIMA, T. A. et al. **Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon**. Remote Sensing, (2019), 11,961. <https://doi.org/10.3390/rs11080961>.

LOCKS, C. J. **Aplicações da Tecnologia Lidar no Monitoramento da Exploração Madeireira em Áreas de Concessão Florestal**; Dissertação de Mestrado em Ciências Florestais, Universidade de Brasília, 2017. 97 p. Disponível em https://repositorio.unb.br/bitstream/10482/23264/1/2017_ChartonJahnLocks.pdf. Acesso em: 13 nov. 2023.

_____. and MATRICARDI, E. A. T. (2019). **Estimativa de impactos da extração seletiva de madeiras na Amazônia utilizando dados LIDAR**. Ciência Florestal, 29(2), 481–495. <https://doi.org/10.5902/1980509826007>.

LOS, S.O. **Analysis of Trends in Fused AVHRR and MODIS NDVI Data for 1982-2006: Indication for a CO₂ Fertilization Effect in Global Vegetation** (2013). *Global Biogeochem. Cycles*, 27, 318–330, doi:10.1002/gbc.20027.

LOURENÇO, P. et al, **Assessing the Performance of Different OBIA Software Approaches for Mapping Invasive Alien Plants Along Roads with Remote Sensing Data**, *International Journal of Applied Earth Observation and Geoinformation*, Volume 95, 2021. <https://doi.org/10.1016/j.jag.2020.102263>.

LU, D. and WENG, Q. (2007) **A survey of image classification methods and techniques for improving classification performance**, *International Journal of Remote Sensing*, 28:5, 823-870, doi: 10.1080/01431160600746456.

LUDERMIR, T. B. (2021). **Inteligência Artificial e Aprendizado de Máquina: Estado Atual e Tendências**. *Estudos Avançados*, 35 (101), 85–94. <https://doi.org/10.1590/s0103-4014.2021.35101.007>.

M. PAL (2005) **Random Forest Classifier for Remote Sensing Classification**, *International Journal of Remote Sensing*, 26:1, 217-222, DOI: 10.1080/01431160412331269698.

MALHI, Y. et al. **The Regional Variation of Aboveground Live Biomass in Old-Growth Amazonian Forests**. *Glob. Change Biol.* 12, 1107–1138 (2006). doi <https://doi.org/10.1111/j.1365-2486.2006.01120.x>.

MASCHLER, J.; ATZBERGER, C.; IMMITZER, M. **Individual Tree Crown Segmentation and Classification of 13 Tree Species Using Airborne Hyperspectral Data**. *Remote Sens.* 2018, 10, 1218. <https://doi.org/10.3390/rs10081218>.

MAPBIOMAS – **Coleção 06 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil**, 2022. Disponível em <https://mapbiomas.org/estatisticas>. Acesso em 04/04/2022.

MASILIŪNAS, D. **Evaluating the Potential of Sentinel-2 and Landsat Image Time Series for Detecting Selective Logging in the Amazon**. A thesis submitted in partial fulfilment of the degree of Master of Science at Wageningen University and Research Centre, The Netherlands,

2017. Disponível em https://www.researchgate.net/profile/Dainius-Masiliunas/publication/350592163_Evaluating_the_potential_of_Sentinel-2_and_landsat_image_time_series_for_detecting_selective_logging_in_the_Amazon/links/606788f8458515614d2e4a46/Evaluating-the-potential-of-Sentinel-2-and-landsat-image-time-series-for-detecting-selective-logging-in-the-Amazon.pdf. Acesso em 17/01/2024.

MATARIRA, D.; MUTANGA, O.; NAIDU, M.; VIZZARI, M. **Object-Based Informal Settlement Mapping in Google Earth Engine Using the Integration of Sentinel-1, Sentinel-2, and PlanetScope Satellite Data**. *Land* (2023), 12, 99. <https://doi.org/10.3390/land12010099>.

MEIRELES, C. **Uso de Técnicas de Inteligência Artificial na Cartografia para a Classificação Supervisionada de Imagens Digitais: um Estudo de Caso do Município de Sabará, Minas Gerais**. Dissertação de Mestrado apresentada ao Programa de Pós Graduação em Geografia – Pontifícia Universidade Católica de Minas Gerais. Orientador: Paulo Fernando Braga Carvalho. Belo Horizonte, 2021. Disponível em http://www.biblioteca.pucminas.br/teses/Geografia_CeciliaGouveaMeireles_19117_Textocompleto.pdf. Acesso em 14/01/2024.

MENESES, P. R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. BRASÍLIA: CNPQ, 2012. Disponível em https://edisciplinas.usp.br/pluginfile.php/5550408/mod_resource/content/3/Livro-SensoriamentoRemoto.pdf. Acesso em 15/01/2024.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO - MAPA. **Monitoramento das Concessões Florestais (2021)**. Disponível em <https://www.gov.br/agricultura/pt-br/assuntos/florestal/concessao-florestal-1/monitoramento-das-concessoes-florestais>. Acesso em: 14 out. 2022.

MÁRIO FILHO. **O Que é Acurácia Em Machine Learning?** (2023). Disponível em <https://mariofilho.com/o-que-e-acuracia-em-machine-learning/>. Acesso em: 22 out. 2023.

MATRICARDI, E. A. T. et al. (2005). **Monitoring Selective Logging in Tropical Evergreen Forests Using Landsat: Multitemporal Regional Analyses in Mato Grosso, Brazil**. Earth Interact. doi: <https://doi.org/10.1175/EI142.1>. Acesso em: 12 nov. 2023.

MAXWELL, A. E.; WARNER, T. A. and FANG Fang (2018) **Implementation of Machine-Learning Classification in Remote Sensing: an Applied Review**, International Journal of Remote Sensing, 39:9, 2784-2817, doi: 10.1080/01431161.2018.1433343.

MAZZEI, L. et al. **Above-Ground Biomass Dynamics After Reduced-Impact Logging in The Eastern Amazon**. Forest Ecology and Management, v. 259, n. 3, p. 367-373, Jan. 2010. ISSN 0378-1127, <https://doi.org/10.1016/j.foreco.2009.10.031>.

MELENDY, L. et al. **Automated Method for Measuring the Extent of Selective Logging Damage with Airborne LiDAR Data**. ISPRS Journal of Photogrammetry and Remote Sensing, Volume 139, 2018, Pages 228-240, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2018.02.022>.

MICHEZ, A. et al. **Characterization of Forests with Lidar Technology**. Land Surface Remote Sensing in Agriculture and Forest, Elsevier, 2016, Pages 331-362, ISBN 9781785481031, <https://doi.org/10.1016/B978-1-78548-103-1.50008-X>.

MINISTÉRIO DO MEIO AMBIENTE - MMA. Instrução Normativa 05/2006. **Procedimentos Técnicos para Elaboração, Apresentação, Execução e Avaliação Técnica de Planos de Manejo Florestal Sustentável.** Disponível em https://snif.florestal.gov.br/images/pdf/legislacao/normativas/in_mma_05_2006.pdf. Acesso em: 02 jun. 2021.

_____. Portaria n - 281, de 16 de julho de 2013. **Autoriza a concessão na Floresta Nacional de Altamira.** Disponível em <http://www.ibama.gov.br/sophia/cnia/legislacao/MMA/PT0281-160713.pdf>. Acesso em: 07 nov. 2023.

MINISTÉRIO DA JUSTIÇA E SEGURANÇA PÚBLICA - MJSP. Portaria nº 535/2020, **Institui o Programa Meio Ambiente Integrado e Seguro - Programa Brasil Mais.** Disponível em <https://www.in.gov.br/en/web/dou/-/portaria-n-535-de-22-de-setembro-de-2020-279178267>. Acesso em: 23 abr. 2022.

MIRANDA, M. D. S. et al. **A High-Spatial Resolution Dataset and Few-shot Deep Learning Benchmark for Image Classification**, 2022 35th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), Natal, Brazil, 2022, pp. 19-24, doi: 10.1109/SIBGRAPI55357.2022.9991746.

MITCHARD, E.T.A. **The tropical forest carbon cycle and climate change.** Nature, vol 559, p. 527-537, 2018. <https://doi.org/10.1038/s41586-018-0300-2>.

MODICA, G; DE LUCA, G.; MESSINA, G. and PRATICÒ, S. (2021) **Comparison and Assessment of Different Object-Based Classifications Using Machine Learning Algorithms and UAVs Multispectral Imagery: a Case Study in a Citrus Orchard and an Onion Crop**, European Journal of Remote Sensing, 54:1, 431-460, DOI: 10.1080/22797254.2021.1951623.

MONTEIRO, A. L. **Monitoramento de indicadores de Manejo Florestal na Amazônia Legal Utilizando Sensoriamento Remoto.** Dissertação de mestrado em Ciências Florestais, Universidade Federal do Paraná. Curitiba/PR, 2005. Disponível em http://www.bibliotecaflorestal.ufv.br/bitstream/handle/123456789/4766/dissertacao_Andre%20Luis%20Silva%20Monteiro%20.pdf?sequence=1. Acesso em: 02 jun. 2021.

MOUNTRAKIS, G. et al. 2011. **Support vector machines in remote sensing: A review**, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 66, Issue 3, 2011, Pages 247-259, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2010.11.001>.

MOUTINHO, P.; RAISSA, G.; AZEVEDO-RAMOS, C. **Achieving Zero Deforestation in the Brazilian Amazon: What is missing?** Elementa: Science of the Anthropocene (2016) 4: 000125. <https://doi.org/10.12952/journal.elementa.000125>.

_____ et al. **Destinação de Florestas Públicas. Um Meio de Combate à Grilagem e ao Desmatamento Ilegal na Amazônia.** Amazônia 2030. Disponível em https://amazonia2030.org.br/wp-content/uploads/2022/03/AMZ2030_30.pdf. Acesso em: 05 abr. 2022.

OLIVEIRA, A. **Integrar para (não) entregar - Políticas Públicas e Amazônia.** 2º ed. Editora Papirus, Campinas, 1991.

OLIVEIRA, A. H. M. et al. **Indicadores de Índícios de Inconformidade Em Planos de Manejo por análise De Consistência Utilizando Sensoriamento Remoto e Movimentação de Créditos Florestais: um Ensaio no Estado do Pará.** In Anais do XX Simpósio Brasileiro de Sensoriamento Remoto – INPE – Florianópolis-SC. (2023). Disponível em <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2023/05.01.18.39/doc/156206.pdf>

OLIVEIRA, P. A. and SILVA, P. de L. **Avaliação da Acurácia Posicional do Mosaico Sentinel-2 para análise de Aplicabilidade na Atualização da Base Cartográfica Contínua na escala 1:100.000 (BC100).** Revista Brasileira de Cartografia, [S. l.], v. 73, n. 3, p. 736–750, (2021). doi: 10.14393/rbcv73n3-55208.

ORFEO. **LargeScaleMeanShift.** CNES. The OTB CookBook (2023). Disponível em https://www.orfeo-toolbox.org/CookBook/Applications/app_LargeScaleMeanShift.html Acesso em 04/01/2024.

_____. **TrainImagesClassifier** CNES. The OTB CookBook (2024a). Disponível em https://www.orfeo-toolbox.org/CookBook/Applications/app_TrainImagesClassifier.html. Acesso em 10/02/2024.

_____. **TrainVectorClassifier** CNES. The OTB CookBook (2024b). Disponível em https://www.orfeo-toolbox.org/CookBook/Applications/app_TrainVectorClassifier.html. Acesso em 10/02/2024.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU. **Outcome Document of the United Nations Conference on Sustainable Development.** The Future We Want. Rio de Janeiro, Brazil, 20–22 June 2012. A/CONF.216/L.1(2012). Disponível em <https://sustainabledevelopment.un.org/futurewewant.html>. Acesso em: 13 nov. 2023.

_____. **Strategic Plan for Forests 2017–2030 and Quadrennial Programme of Work of The United Nations Forum on Forests for The Period 2017–2020** E/RES/2017/4 (2017). Disponível em <https://www.un.org/esa/forests/documents/un-strategic-plan-for-forests-2030/index.html>. Acesso em: 13 nov. 2023.

PACHECO, A. K. **Vizinhos mais Próximos - K-NN** (2017). Disponível em <http://computacaointeligente.com.br/algoritmos/k-vizinhos-mais-proximos>. Acesso em: 25 fev. 2023.

PARANHOS FILHO, A. C.; MIOTO C. L.; PESSI, D. D.; GAMARRA, R. M.; DA SILVA, N. M.; RIBEIRO, V.; CHAVES, J. R. **Geotecnologias para Aplicações Ambientais**. Maringá, PR. Uniedusul. Editora, 2020

PATAUÁ FLORESTAL Ltda. **Plano de Manejo Florestal Sustentável de Uso Múltiplo UMF III – Lote de Concessão Florestal da Floresta Nacional de Altamira**. Belém, 2015. Disponível em https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/concessoes-florestais-em-andamento-1/copy_of_pmfs_Pataua_umf3_altamira.pdf. Acesso em: 13 nov. 2023.

_____. **Plano Operacional Anual. POA 4D. Floresta Nacional de Altamira. Unidade de Manejo Florestal IV** (2019). Disponível em <https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/concessoes-florestais-em-andamento-1/pataua-florestal-ltda-execucao-financeira-e-tecnica-da-concessao-altamira-umf-iv>. Acesso em: 13 nov. 2023.

_____. **Relatório de Atividades do Plano de Operações Anual POA 4D. Floresta Nacional de Altamira. Unidade de Manejo Florestal IV** (2021).

PEREIRA, P. et al. **Forest Canopy Damage and Recovery in Reduced-Impact and Conventional Selective Logging in Eastern Para, Brazil**, *Forest Ecology and Management*, Volume 168, Issues 1–3, 2002, Pages 77-89, ISSN 0378-1127, [https://doi.org/10.1016/S0378-1127\(01\)00732-0](https://doi.org/10.1016/S0378-1127(01)00732-0).

PEREIRA, V. **Uso de Imagens Wpm/Cbers 04a para Análise da Situação das Áreas de Preservação Permanente no Distrito Federal**. Dissertação de Mestrado, apresentada ao Programa de Pós-Graduação em Ciências Ambientais da Faculdade UnB Planaltina, Orientador: Dr. Rodrigo Studart Corrêa, Brasília, 2021. Disponível em http://icts.unb.br/jspui/bitstream/10482/42686/1/2021_VitorCarlosPereira.pdf. Acesso em 14/01/2024.

PESSANHA, M. S., ANTUNES, M. A. H. **Avaliação da qualidade posicional planimétrica de imagens MSI do Sentinel-2A: estudo de caso do município Dom Pedrito-RS**. In: Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos-SP. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019.

PHIRI, D.; MORGENROTH, J. **Developments in Landsat Land Cover Classification Methods: A Review**. *Remote Sens.* 2017, 9, 967. <https://doi.org/10.3390/rs9090967>

PIAO, S.; Fang, J.; Liu, H. and Zhu, B. **NDVI-Indicated Decline in Desertification in China in the Past Two Decades** (2005). *Geophys. Res. Lett.*, 32, L06402, doi:10.1029/2004GL021764.

PLANET TEAM (2022). **Planet Imagery Product Specifications**. San Francisco, CA”. Disponível em https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. Acesso em: 13 fev. 2023.

PIMM et al. **The Biodiversity of Species and Their Rates of Extinction, Distribution, and Protection**. *Science*.344,1246752(2014). doi:10.1126/science.1246752.

PINAGÉ, E. **Mapeamento e análise do corte seletivo em uma cena Landsat 5 TM no Estado do Pará**. In: Anais do Simpósio Brasileiro de Sensoriamento Remoto – SBSR, 12, 2011, Curitiba, PR. São José dos Campos: INPE. p. 1798-1735.

PING, D.; Dalagnol, R.; Galvão, L.S.; Nelson, B.; Wagner, F.; Schultz, D.M.; Bispo, P.d.C. **Assessing the Magnitude of the Amazonian Forest Blowdowns and Post-Disturbance Recovery Using Landsat-8 and Time Series of PlanetScope Satellite Constellation Data**. *Remote Sens*. 2023, 15, 3196. <https://doi.org/10.3390/rs15123196>.

PINHEIRO, E. et al. (2021). **Validação da Aplicação de Imagens Planet à Regularização Ambiental de Imóveis Rurais no Mato Grosso do Sul**. Anuário do Instituto de Geociências – UFRJ. Disponível em <https://revistas.ufrj.br/index.php/aigeo/article/view/31191/17669>. Acesso em 25/01/2024.

PUTZ, F.E. et al., 2012: **Sustaining Conservation Values in Selectively Logged Tropical Forests: The attained and The Attainable**. *Conserv. Lett.*, 5, 296–303, doi:10.1111/j.1755-263X.2012.00242.x.

QIN, Y. et al. **Carbon Loss From Forest Degradation Exceeds that From Deforestation in the Brazilian Amazon**. *Nat. Clim. Chang.* 11, 442–448 (2021). <https://doi.org/10.1038/s41558-021-01026-5>.

RAJ, J. and SRINIVASULU, S. "Change Detection of Images Based on Multivariate Alteration Detection Method," 2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India, 2020, pp. 847-850, doi: 10.1109/ICACCS48705.2020.9074298.

READ, J. M. et al. **Application of Merged 1-m and 4-m Resolution Satellite Data to Research and Management in Tropical Forests**. *Journal of Applied Ecology*, vol. 40, no. 3, 2003, pp. 592–600, <http://www.jstor.org/stable/3506030>. Acesso em: 15 abr. 2022.

REDE MAIS, **Programa Brasil Mais - Meio Ambiente Integrado e Seguro**. [2023]. Disponível em <https://plataforma-pf.scon.com.br/#/>. Acesso em: 06 fev. 2023.

RIOS, D. C. **Análise do Distrito Florestal Sustentável da BR-163 na perspectiva de instrumento de política florestal**. Monografia apresentada ao Curso de Engenharia Florestal. Universidade Federal do Rio de Janeiro - UFRJ (2007). Disponível em http://www.bibliotecaflorestal.ufv.br/bitstream/handle/123456789/8075/2006_2_Daniel-Cataldo-Lopes-Rios.pdf?sequence=1&isAllowed=y. Acesso em: 13 nov. 2023.

RODRIGUES, D. A. et al. **Análise dos Sistemas Degrad e Detex em Áreas de Fronteira Agropecuária da Amazônia**. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto – SBSR. Santos, 2019. p. 3515-3517.

_____. (2003b) **Spatial Analyses of Logging Impacts in Amazonia Using Remotely-Sensed Data**. Photogrammetric Engineering and Remote Sensing, 69, 275–282. Disponível em https://www.asprs.org/wp-content/uploads/pers/2003journal/march/2003_mar_275-282.pdf. Acesso em: 13 nov. 2023.

REMIGIO, 2020. **Máquina de Vetores de Suporte — SVM**. Disponível em <https://medium.com/@msremigio/m%C3%A1quinas-de-vetores-de-suporte-svm-77bb114d02fc>. Acesso em 27/02/2023.

ROODPOSHTI, S.; LUCIEER, A.; ANEES, A.; BRYAN, B.A. **A Robust Rule-Based Ensemble Framework Using Mean-Shift Segmentation for Hyperspectral Image Classification**. Remote Sens. 2019, 11, 2057. <https://doi.org/10.3390/rs11172057>

SALATI, E. **O Clima Atual depende da Floresta**. In **Amazônia: desenvolvimento, integração e ecologia**. São Paulo. Ed. Brasiliense (1983).

SANTOS, D. et al. **Índice de Progresso Social na Amazônia Brasileira - IPS Amazônia 2021. Resumo Executivo**. Imazon, 2021. Disponível em https://amazonia2030.org.br/wp-content/uploads/2022/03/ResExec_ipsAmazonia2021_n23_16fev2022.pdf. Acesso em: 18 out. 2022.

SANTOS, E. M. **Teoria e Aplicação de Support Vector Machines à Aprendizagem e Reconhecimento de Objetos Baseado na Aparência**. Dissertação de mestrado em Informática. Universidade Federal da Paraíba - UFPB. Campina Grande/ PB, 2002. Disponível em http://docs.computacao.ufcg.edu.br/posgraduacao/dissertacoes/2002/Dissertacao_EulandaMirandadosSantos.pdf. Acesso em: 13 nov. 2023.

SCHMITT, J., 2015. **Crime Sem Castigo: a Efetividade da Fiscalização Ambiental para o Controle do Desmatamento Ilegal na Amazônia**. Tese de doutorado. Centro de Desenvolvimento Sustentável. Universidade de Brasília - UnB, Brasília. Disponível em http://repositorio.unb.br/bitstream/10482/19914/1/2015_JairSchmitt.pdf. Acesso em: 13 nov. 2023.

SERVIÇO FLORESTAL BRASILEIRO - SFB. **Concessão Florestal - Benefícios Ambientais e Sociais** (2022a). Disponível em <https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/beneficios-ambientais-e-sociais>. Acesso em 29 set. 2023.

_____. **Plano Anual de Outorga Florestal – PAOF 2023**. [2022b]. Disponível em https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/plano-anual-de-outorga-florestal/Paof_2023.pdf. Acesso em: 02 jan. 2023.

SHUBART, H. **Ecologia e Utilização das Florestas**. in Amazônia: Desenvolvimento Integração e Ecologia – São Paulo: ed. Brasiliense : Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, 1983.

SILVA, J. L. **Danos Florestais e Estimativa da Redução no Estoque de Carbono em Áreas de Manejo Florestal sob Concessão Pública: Floresta Nacional do Jamari – RO, Brasil**. Dissertação de mestrado – Instituto Nacional de Pesquisas da Amazônia - INPA. Manaus/AM, 2014. Disponível em https://bdtd.inpa.gov.br/bitstream/tede/1707/5/Disserta%20a7%20a3o_%20J%20a9ssi%20Luane%20Silva.pdf. Acesso em: 02 jun. 2021.

SIMÕES et al., 2023. **Combinação de Dados Sentinel no Mapeamento do Uso e Cobertura do Solo da Rebio Nascentes da Serra do Cachimbo**. Anais do XX Simpósio Brasileiro de Sensoriamento Remoto – INPE – Florianópolis-SC, 2023. Disponível em <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2023/05.14.23.08/doc/156103.pdf>. Acesso em 14/01/2024.

SINGH, J. **Random Forest: Pros and Cons** (2020). Disponível em <https://medium.datadriveninvestor.com/random-forest-pros-and-cons-c1c42fb64f04>. Acesso em: 19 nov. 2022.

SOARES FILHO, B. **Interpretação de Imagens da Terra**. Curso de Especialização em geoprocessamento (Apostila). Departamento de Geografia – Universidade Federal de Minas Gerais (UFMG) 2020. Disponível em <https://www.csr.ufmg.br/geoprocessamento/publicacoes/intimagem.pdf>. Acesso em: 13 nov. 2023.

SOSA-HERRERA, J.A.; Vallejo-Pérez, M.R.; Álvarez-Jarquín, N.; Cid-García, N.M.; LÓPEZ-ARAUJO, D.J. **Geographic Object-Based Analysis of Airborne Multispectral Images for Health Assessment of Capsicum annum L. Crops**. Sensors 2019, 19, 4817. <https://doi.org/10.3390/s19214817>

SOUZA JR., C.; ROBERTS, D. and COCHRANE, M. **Combining Spectral and Spatial Information to Map Canopy Damage from Selective Logging and Forest Fires**. Remote Sensing of Environment, Elsevier, 2005, 98, 329-343. <https://doi.org/10.1016/j.rse.2005.07.013>.

SRUTHI, E. **Understand Random Forest Algorithms With Examples** (2023). Disponível em <https://www.analyticsvidhya.com/blog/2021/06/understanding-random-forest/>. Acesso em: 03 out. 2023.

STEEGE, H. et al. **Hyperdominance in the Amazonian Tree Flora**. *Science*.342,1243092(2013).doi:10.1126/science.1243092.

STOLL, E. et al. **Detecting Gold Mining Impacts on Insect Biodiversity in a Tropical Mining Frontier with Smallsat Imagery**. *Remote Sensing in Ecology and Conservation*. Vol 08 – June 2022. <https://doi.org/10.1002/rse2.250>.

ŠTULAR, B.; EICHERT, S.; LOZIĆ, E. **Airborne LiDAR Point Cloud Processing for Archaeology. Pipeline and QGIS Toolbox**. *Remote Sens.* 2021, 13, 3225. <https://doi.org/10.3390/rs13163225>.

TANAJURA, E.; ANTUNES, M. and UBERTI, M. **Avaliação de Índices de Vegetação para a Discriminação de Alvos Agrícolas em Imagens de Satélites**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia/GO, 2005. Disponível em <http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.20.10.16/doc/301.pdf>. Acesso em: 02 jun. 2021.

THAN NOI, P. and KAPPAS, M. **Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery**. *Sensors* 2018, 18, 18. <https://doi.org/10.3390/s1801001>

THOMPSON, I. D. et al. **An operational framework for defining and monitoring forest degradation**. *Ecology and Society* 18(2): 20. [2013]. Disponível em <http://www.jstor.org/stable/26269330>. Acesso em: 13 nov. 2023.

TRISASONGKO, B.H.; et al. (2017). **Comparing six pixel-wise classifiers for tropical rural land cover mapping using four forms of fully polarimetric SAR data**. *Int. J. Rem. Sens.* 38 (11), 3274–3293. <https://doi.org/10.1080/01431161.2017.1292072>.

ULLOA, Y.; HERZSPRUNG, S. **Object based Classification**. (2020). Disponível em https://rpubs.com/delViento/obia_rf_test. Acesso em 02/01/2024.

UMUNAY, P.M. et al. **Selective logging emissions and potential emission reductions from reduced-impact logging in the Congo Basin**. *For. Ecol. Manage.*, 437, 360–371, doi:10.1016/j.foreco.2019.01.049. [2019].

VALDIONES, A. P. et al. **A Evolução do setor madeireiro na Amazônia entre 1980 e 2020 e as oportunidades para o seu desenvolvimento inclusivo e sustentável na próxima década** / Belém, PA. Disponível em <https://www.imaflora.org/public/media/biblioteca/evolucao-do-setor-madeireiro-na-amazonia-de-1980-a-2020.pdf>. Acesso em: 03 out. 2022.

VAN DER ENT, R. et al. **Origin and Fate of Atmospheric Moisture Over Continents**, Water Resour. Res.,46, W09525, doi:10.1029/2010WR009127. [2010].

VARGAS JUNIOR, E. C. **Support Vector Machine. Apresentação** Universidade Federal de Santa Catarina – UFSC, [2020]. Disponível em <https://geam.paginas.ufsc.br/files/2020/02/svm.pdf>. Acesso em: 30 nov. 2022.

VAZ, A. L. **Classificando o paladar de receitas — SVM**. (2018) Disponível em <https://arthurlambletvaz.medium.com/classificando-o-paladar-das-receitas-svm-bf0fbb185b10>. Acesso em: 30 nov. 2022.

VERAS, D. **Análise Temporal Multifonte e Multiespectral da Cobertura Vegetal do Estuário do Rio Sirinhaém – PE**. Dissertação apresentada ao Programa de PósGraduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco. Orientador: Prof. Dr. João Rodrigues Tavares Júnior, Recife, 2022. Disponível em <https://repositorio.ufpe.br/bitstream/123456789/46530/1/DISSERTA%C3%87%C3%83O%20Daniel%20Silva%20Veras.pdf>. Acesso em 14/01/2024.

WELSINK et al. **Towards the use of Satellite-Based Tropical Forest Disturbance Alerts to Assess Selective Logging Intensities**. Environmental Research Letters, Volume 18, Number 5 (2023). DOI 10.1088/1748-9326/acd018

WENG, Q. **Remote Sensing and GIS Integration - Theories, Methods, and Applications**. New York : McGraw-Hill, (2010). 397 p.

XIAO et al., **Structured Mean Shift Method and its Application on Image Segmentation**. Journal of Theoretical and Applied Information Technology 31st October 2012. Vol. 44 No.2 Disponível em <https://www.jatit.org/volumes/Vol44No2/19Vol44No2.pdf>. Acesso em 04/01/2024.

YIU, T. **Understanding Random Forest - How the Algorithm Works and Why it is so Effective** [2019]. Disponível em <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>. Acesso em: 07set. 2022.

YONG, L. et al. **Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis**, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 68, 2012, Pages 144-156, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2012.01.007>.

YU, L. et al. **Meta-Discoveries Form a Synthesis of Satellite-Based Land-Cover Mapping Research**. International Journal of Remote Sensing 35 (13): 4573–4588. doi:10.1080/01431161.2014.930206. [2014].

ZIEGELMAIER NETO, B. **Classificação dos estágios de sucessão da Floresta Atlântica utilizando dados multiplataforma orbitais e ALS.** Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal da Universidade do Estado de Santa Catarina. Orientador: Marcos Benedito Schimalski. Lages, RS, 2022. Disponível em https://www.udesc.br/arquivos/cav/id_cpmenu/3428/Dissertacao_Bill_final_168501865119_04_3428.pdf. Acesso em 14/01/2024.

ANEXOS

ANEXO A. Resultados dos Mapeamentos da UPA 4D.

ANEXO B. Resultados dos Mapeamentos da Área de Controle da UPA 4D