

REGINALDO ARTHUR GLORIA MARCELINO

**IDENTIFICAÇÃO E QUANTIFICAÇÃO DE RESÍDUOS MADEIREIROS PÓS-
COLHEITA FLORESTAL USANDO SEGMENTAÇÃO DE IMAGENS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, para obtenção do título de *Magister Scientiae*.

Orientador: Alexandre Simões Lorenzon

Coorientadores: Gustavo Eduardo Marcatti
Ernani Lopes Possato

**VIÇOSA - MINAS GERAIS
2023**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

M314i
2023

Marcelino, Reginaldo Arthur Glória, 1994-
Identificação e quantificação de resíduos madeireiros
pós-colheita florestal usando segmentação de imagem /
Reginaldo Arthur Glória Marcelino. – Viçosa, MG, 2023.
1 dissertação eletrônica (86 f.): il. (algumas color.).

Inclui apêndice.

Orientador: Alexandre Simões Lorenzon.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Engenharia Florestal, 2023.

Referências bibliográficas: f. 62-76.

DOI: <https://doi.org/10.47328/ufvbbt.2024.087>

Modo de acesso: World Wide Web.

1. Resíduos vegetais - Identificação. 2. Engenharia
geotécnica. 3. Gestão da qualidade total. 4. Monitorização
ambiental. 5. Algoritmos. 6. Segmentação de imagem.
I. Lorenzon, Alexandre Simões, 1980-. II. Universidade Federal
de Viçosa. Departamento de Engenharia Florestal. Programa de
Pós-Graduação em Ciência Florestal. III. Título.

GFDC adapt. CDD 22. ed. 634.95879

Bibliotecário(a) responsável: Alice Regina Pinto Pires CRB-6/2523

REGINALDO ARTHUR GLÓRIA MARCELINO

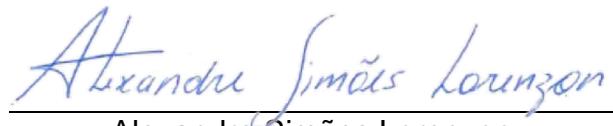
IDENTIFICAÇÃO E QUANTIFICAÇÃO DE RESÍDUOS MADEIREIROS PÓS-COLHEITA FLORESTAL USANDO SEGMENTAÇÃO DE IMAGENS

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, para obtenção do título de *Magister Scientiae*.

APROVADA: 11 de dezembro de 2023.

Assentimento:


Reginaldo Arthur G. Marcelino
Reginaldo Arthur Gloria Marcelino
Autor


Alexandre Simões Lorenzon
Alexandre Simões Lorenzon
Orientador

*Dedico este trabalho aos meus pais, Amélia Florenci, José Reinaldo
e ao meu irmão Reinaldo Júnio.*

AGRADECIMENTOS

A Deus pelo suporte e auxílio em todos os momentos.

Ao universo e as energias transcendentais da natureza em meu dia a dia.

A minha família por todo suporte e apoio nos momentos de alegria e sufoco.

Aos amigos que me apoiaram em toda essa linda jornada. E a todos que me acompanharam e me ajudaram durante o tempo que passei em Viçosa MG.

Ao meu orientador Alexandre pela dedicação e ensinamentos, mesmo tendo iniciado o mestrado durante um período turbulento da sociedade, meu muito obrigado pela troca e partilha sempre.

Aos meus coorientadores Gustavo (por estar junto comigo desde a graduação, obrigado por tudo), e ao Ernani (pessoa incrível que me ajudou demais no desenvolvimento da dissertação).

As empresas participantes do projeto, e aqui me estendo as pessoas envolvidas direta e indiretamente nesse projeto (você que viveu comigo sabe que fez parte disso).

A você que está lendo aqui, muito obrigado.

À Universidade Federal de Viçosa, pela oportunidade de realizar a pós-graduação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos.

“É necessário ter o caos dentro de si para gerar uma estrela.”

(Friedrich Nietzsche)

“Ninguém ignora tudo. Ninguém sabe tudo. Todos nós sabemos alguma coisa. Todos nós ignoramos alguma coisa. Por isso aprendemos sempre.”

(Paulo Freire)

“Não existe um caminho para a felicidade. A felicidade é o caminho.”

(Mahatma Gandhi)

RESUMO

MARCELINO, Reginaldo Arthur Glória, M.Sc., Universidade Federal de Viçosa, dezembro de 2023. **Identificação e quantificação de resíduos madeireiros pós-colheita florestal usando segmentação de imagens.** Orientador: Alexandre Simões Lorenzon. Coorientadores: Gustavo Eduardo Marcatti e Ernani Lopes Possato.

No âmbito das atividades florestais, a colheita florestal surge como a operação mais onerosa na produção de madeira, superando potencialmente 50% do valor total da madeira na fábrica. Os resíduos de madeira, deixados no campo, representam uma perda econômica substancial, entre 2% e 15% do volume total de madeira comercial. Nesse contexto, o emprego de sensores embarcados em aeronave remotamente pilotada surge como uma solução inovadora para a identificação e mensuração desses resíduos florestais. Assim, o presente estudo se propôs a desenvolver uma metodologia para identificar e quantificar resíduos madeireiros pós-colheita, considerando dimensões comerciais (comprimento > 3 m e diâmetro > 4 cm), por meio de imagens de alta resolução espacial capturadas por Aeronave remotamente pilotada. A pesquisa foi conduzida em áreas específicas de plantios comerciais de eucalipto no estado de São Paulo, Brasil, sob dois sistemas de colheita florestal tora curta e tora longa. As imagens foram adquiridas por aeronave remotamente pilotada em RGB, em três alturas diferentes, para tora curta (60, 90 e 120 m) e tora longa (40, 60 e 80 m). Foi desenvolvido um algoritmo (script) em Python por meio da biblioteca OpenCV, com aplicação de técnicas para segmentação de bordas e detecção de objetos. A validação de campo foi realizada com alocação de parcelas circulares na proporção 1:1ha, e a cubagem pelo método Smalian para cálculo dos desvios volumétricos. A acurácia das imagens com as toras identificadas foi avaliada pelo índice AcATaMa para classificação (0 - Não resíduo e 1 Resíduo). A metodologia foi eficiente para identificação e quantificação dos resíduos, em que, as alturas de 120 m para toras curtas e 80 m para toras longas apresentaram as melhores acurácia, atingindo valores de 0,88 e 0,85, respectivamente, e ainda com desvios volumétricos percentuais inferiores a 2,5%. Foi observado um padrão de quanto menor o tamanho do pixel mais complexo a detecção dos objetos pelo algoritmo. Essa análise tem impacto direto na eficiência operacional de aquisição de imagens por Aeronave remotamente pilotada, devido a aumentar o rendimento em hectares avaliados. A

diversidade nas dimensões dos resíduos destaca a necessidade de ajustes específicos no algoritmo para garantia da identificação precisa de toras para cada sistemas de colheita. No sistema de toras curtas, cerca de 84% do volume total é composto por toras com comprimentos superiores a 3 metros, enquanto no sistema de toras longas esse valor é aproximadamente 68%. Os filtros de suavização, foram cruciais para o sucesso do processamento do algoritmo, quanto a identificação precisa das toras nas imagens, devido ao aumento da precisão na etapa de detecção de bordas. Essa abordagem de Análise de Objetos Baseada em Imagem (OBIA) em ambiente Python mostrou-se promissora, ao abrir oportunidades de melhorias contínuas da automatização dessas atividades de inventário florestal de resíduos por imagem. Os resultados obtidos destacam a flexibilidade, reproduzibilidade e aplicabilidade desta metodologia no monitoramento de áreas colhidas, ao promover a implementação de ações para melhoria da gestão de qualidade nas operações de colheita e silvicultura subsequentes.

Palavras-chave: Geotecnologia; Gestão de qualidade; Monitoramento; Algoritmo; Segmentação de objetos;

ABSTRACT

MARCELINO, Reginaldo Arthur Glória, M.Sc., Universidade Federal de Viçosa, December, 2023. **Identification and quantification post-harvest forests wastes using image segmentation.** Adviser: Alexandre Simões Lorenzon. Co-advisers: Gustavo Eduardo Marcatti and Ernani Lopes Possato.

In the context of forestry activities, forest harvesting emerges as the costliest operation in timber production, potentially exceeding 50% of the total timber value at the factory. Forest wastes left in the field represent a substantial economic loss, ranging from 2% to 15% of the total volume of commercial wood. In this scenario, the use of sensors mounted on drone emerges as an innovative solution for the identification and measurement of these forest residues. Therefore, this study aimed to develop a methodology to identify and quantify post-harvest forests wastes, considering commercial dimensions (length > 3 m and diameter > 4 cm), through high spatial resolution images captured by drone. The research was conducted in specific areas of commercial eucalyptus plantations in the state of São Paulo, Brazil, under two forest harvesting systems: Cut-To-Length and Tree Length. Images were acquired by drone in RGB, at three different heights for Cut-To-Length (60, 90, and 120 m) and Tree Length (40, 60, and 80 m). A Python algorithm was developed using the OpenCV library, applying techniques for edge segmentation and object detection. Field validation was performed by allocating circular plots in a 1:1 ha ratio, and volume discrepancies were calculated using the Smalian method. The accuracy of images with identified logs was evaluated using the AcATaMa index for classification (0 - No residue and 1 - Residue). The methodology was efficient for the identification and quantification of forest wastes, with heights of 120 m for Cut-To-Length and 80 m for Tree Length presenting the highest accuracies, reaching values of 0.88 and 0.85, respectively, with volumetric percentage discrepancies below 2.5%. A pattern was observed where the smaller the pixel size, the more complex the object detection by the algorithm. This analysis has a direct impact on the operational efficiency of drone image acquisition, as it increases the yield in evaluated hectares. The diversity in forests wastes dimensions highlights the need for specific adjustments in the algorithm to ensure accurate log identification for each harvesting system. In the Cut-To-Length system, about 84% of the total volume consists of logs longer than 3 meters, while in

the Tree Length system, this value is approximately 68%. Smoothing filters were crucial for the success of the algorithm processing, enhancing precision in the edge detection phase and ensuring accurate log identification in the images. This Object-Based Image Analysis (OBIA) approach in the Python environment has proven promising by opening opportunities for continuous improvement in the automation of forest wastes inventory through imagery. The results underscore the flexibility, reproducibility, and applicability of this methodology in monitoring harvested areas, promoting the implementation of actions to enhance quality management in subsequent harvesting and silviculture operations.

Keywords: Geotechnology; Quality management; Monitoring; Algorithm; Object segmentation;

LISTA DE ILUSTRAÇÕES

Figura 01: Tipos de classificações de imagens e as subdivisões quanto às técnicas, diferenciações e principais algoritmos ou ferramentas utilizados. Fonte: Autor, (2023), adaptado de (Haralick et al. 1973; Lu & Weng, 2007; Abburu & Golla, 2015; Ma et al. 2017; Lv & Wang, 2020; Imani & Ghassemian, 2020; Bhojanapalli et al. 2021).

Figura 02: Ilustração da direção do gradiente para a definição e constituição do que é a borda no objeto. Fonte: OpenCV, (2023a).

Figura 03: Ilustração da composição de quais serão arestas-linhas e quais não, sob a ótica dos valores limites, *minVal* e *maxVal*. Fonte: OpenCV, (2023a).

Figura 04: Localização dos talhões onde foram coletados os dados de resíduos madeireiros pós-colheita florestal, sob os cenários avaliados. Fonte: Autor, (2023).

Figura 05: Distribuição amostral aleatória das parcelas para validação em campo do modelo de identificação e quantificação proposto para as áreas de estudo (A) tora curta, e (B) tora longa. Fonte: Autor (2023).

Figura 06: Parcela amostral no campo, e forma adotada para delimitar o centro da parcela e identificação das toras. Fonte: Autor, (2023).

Figura 07: Esquema ilustrativo da medição nas toras para cálculo da cubagem Smalian dos resíduos nas parcelas. Fonte: Autor, (2023).

Figura 08: Etapas e funções do algoritmo *OpenCV* utilizadas no processamento das imagens para obtenção da identificação e quantificação dos resíduos florestais pós-colheita. Fonte: Autor, (2023).

Figura 09: Etapas sequenciais utilizadas para o processamento das imagens via algoritmo para os dois sistemas, após avaliação dos resultados. Fonte: Autor, (2023).

Figura 10: Detecção de bordas e segmentação de objetos pelo algoritmo nas diferentes alturas avaliadas: 1) sistema de toras longas 2) sistema de toras curtas. Fonte: Autor, (2023).

Figura 11: Identificação das toras pelo algoritmo nas diferentes alturas avaliadas: 1) sistema de toras longas 2) sistema de toras curtas. Fonte: Autor, (2023).

Figura 12: Distribuição do volume dos resíduos por classe de comprimento e de diâmetro para o sistema de toras curtas. Fonte: Autor, (2023).

Figura 13: Distribuição do volume dos resíduos por classe de comprimento e de diâmetro para o sistema de toras longas. Fonte: Autor, (2023).

Figura 14: Intensidade das bandas espectrais sob a influência da função *Canny* do sistema de toras curtas, nos voos (A – 60, B – 90 e C – 120 m). Fonte: Autor, (2023).

Figura 15: Intensidade das bandas espectrais sob a influência da função *Canny* do sistema de toras longas, nos voos (A – 40, B – 60 e C – 80 m). Fonte: Autor, (2023).

LISTA DE TABELAS

Tabela 01: Descrição dos atributos de coletas de acordo com o sistema adotado a fim de obter variação de dados para o algoritmo.

Tabela 02: Dados descritivos referentes a cubagem dos resíduos totais e comerciais estimados para a área total dos talhões, destinada ao modelo de tora curta e tora longa.

Tabela 03: Valores testados no algoritmo com intuito de identificar os melhores parâmetros para cada cenário avaliado.

Tabela 04: Diferentes atributos e parâmetros testados no algoritmo comparados aos resultados da cubagem de campo para os dois cenários tora curta e longa.

LISTA DE SIGLAS E ABREVIATURAS

OBIA - Análise de Imagem Orientada Ao Objeto

OpenCV - Open-Source Computer Vision Library

ODS – Objetivos Desenvolvimento Sustentável

ONU - Organizações das Nações Unidas ONU

ARP - Aeronave Remotamente Pilotada

VANT - Aeronave remotamente pilotada

ANATEL - Agência Nacional de Telecomunicações

ANAC - Agência Nacional de Aviação Civil

DECEA - Departamento de Controle do Espaço Aéreo

SARPAS/RPAS - Solicitação de Acesso de Aeronaves Remotamente Pilotadas

minVal – Valores mínimos

maxVal – Valores máximos

AcATaMa - Avaliação da Classificação de Imagens com Técnicas de Aprendizado de
Máquina

RGB – Bandas espectrais R (vermelha), G (verde) e B (azul)

DesvPad. – Desvio padrão

LISTA DE SÍMBOLOS

θ - ângulo dos gradientes

m – metros

cm – centímetros

h – horas

ha – hectares

% - Porcentagem.

SUMÁRIO

1. INTRODUÇÃO	17
2. REVISÃO DE LITERATURA	19
2.1 A colheita florestal	19
2.1.1 Apresentação geral	19
2.1.2 Sistemas de colheita florestal na geração de resíduos	19
2.1.3 Gestão de Qualidade na colheita florestal.....	21
2.2 Geotecnologias	23
2.2.1 Sensoriamento remoto	23
2.2.2 Uso de aeronave remotamente pilotada para coleta de imagens	24
2.3 Classificação de imagens digitais.....	25
2.3.1 Técnicas de classificação de imagens	25
2.3.1.1 Fotointerpretação e os processos de classificação	27
2.3.1.2 Classificação não supervisionada	27
2.3.1.3 Classificação supervisionada	27
2.3.1.4 Classificação semi supervisionada.....	28
2.3.1.5 Classificação orientada ao objeto - OBIA	29
2.4 Técnicas de segmentação e detecção de objetos.....	31
2.4.1 Biblioteca OpenCV – conceituação	31
2.4.2 Biblioteca OpenCV– Detecção de bordas (Canny)	32
2.4.3 Biblioteca OpenCV– Detecção de geometria	34
3. MATERIAIS E MÉTODOS	35
3.1 Área de estudo	35
3.2 Aquisição das imagens (Ortomosaico)	37
3.3 Levantamento de campo	38
3.4 Pré-processamento das imagens.....	42
3.5 Processamento das imagens	43
3.5.1 Etapas do processamento das imagens.....	43
3.6 Script do modelo de identificação e quantificação (Rotina via Python)	45
3.7 Avaliação estatística do algoritmo	45
4.1 Algoritmo de identificação e quantificação	46
4.2 Distribuição de resíduos.....	52
4.3 Processamento, novos passos e melhorias	55
5. CONCLUSÕES	60

REFERÊNCIAS.....	62
APÊNDICE A - Script	77

1. INTRODUÇÃO

Dentre as atividades florestais, a colheita florestal é a operação de maior custo à madeira posta na fábrica, com potencial de ultrapassar 50% do valor da madeira. As atividades de colheita incluem corte, extração, carregamento da madeira nos veículos de transporte e demais operações que venham a ocorrer no talhão florestal (Machado et al. 2014; Nakahata et al. 2014). Diversas variáveis podem influenciar o desempenho e a qualidade dessas operações, sendo identificadas por meio de estudos com estimativas da produtividade, eficiência e custos, além do que o custo médio da madeira extraída tende a aumentar proporcionalmente ao desperdício de madeira em campo (Barreto et al. 1998; Simões & Fenner, 2010; Rotili et al. 2022).

O desperdício de madeira ao longo da atividade de colheita, ocorre principalmente quando parte do material lenhoso de interesse eventualmente é deixada no campo, e a perda econômica pode variar entre 2 e 15% do volume de madeira comercial colhida no talhão (Nakahata et al. 2014; Serpe et al. 2018). Mesmo com todos os cuidados nas especificações, ainda pode-se ter volume significativo de resíduos lenhosos com potencial de serem convertidos em matéria prima, sejam para fins energéticos e/ou celulósicos (Kizha & Han, 2016; IBA, 2023; 2023a).

Os resíduos madeireiros podem estar na forma de: tocos, toras de dimensões comerciais, ponteiros de fuste, toras ou feixes de madeira deixados inadvertidamente dentro do talhão ou concentrados na beira das estradas, toras quebradas ou mortas (Machado et al. 2014; Kizha & Han, 2016). Além de não gerar receita, toda essa madeira residual prejudica a movimentação das máquinas que realizam as operações posteriores de silvicultura, como preparo do solo e de plantio; logo, aumentam-se os custos dessas atividades (De Graaf et al. 2003; Kizha & Han, 2016).

A identificação e quantificação dos resíduos florestais são cruciais para orientar iniciativas de aprimoramento da eficiência das operações em campo, a fim de garantir a redução de custos e perdas durante a colheita e transporte da madeira. No entanto, o método tradicional de quantificação dos resíduos em campo é complexo, demorado e dispendioso, ao exigir que equipes percorram o talhão para identificar, classificar e mensurar os resíduos de madeira. Realizar um censo pós-colheita com esses métodos convencionais ou mesmo a amostragem em grade, que é desenhar manualmente as dimensões da tora, é impraticável devido ao alto custo e tempo

envolvido. Além disso, essas abordagens apresentam margens de erro significativas, o que compromete a precisão dos resultados e prolonga o processo de análise, prejudicando as abordagens da gestão de qualidade.

Contudo o uso de geotecnologias para identificação e quantificação dos resíduos, por meio de aquisição remota de imagens são alternativas viáveis do ponto de vista operacional e econômico para a redução de custos nas atividades de campo (Sowa, 2014; Oliveira et al. 2020). Além do aprimoramento da gestão da qualidade pois reduz o tempo de medição quando comparado ao método tradicional de medição *in situ* (Ståhl et al. 2001; Kizha & Han, 2015; Shokirov et al. 2021).

A utilização de sensores embarcados em Aeronave remotamente pilotada abre novas perspectivas para a quantificação dos resíduos florestais. Essa abordagem é altamente eficaz porque fornece informações detalhadas sobre as características dos materiais presentes nas imagens. Essa técnica não se limita apenas a contextos florestais, mas pode ser aplicada em uma variedade de áreas, incluindo mapeamento urbano, rural, geológico e agrícola de precisão. Essa abordagem possibilita monitoramento constante dos resíduos, além de contribuir para a indicação de áreas críticas com elevado desperdício de madeira, ao gerar percepções importantes na melhoria da gestão de qualidade em processos florestais nas empresas (Santos & Faria, 2017; Braz et al., 2017; Bargos & Matias, 2018; Embrapa, 2019; Dainelli et al. 2021; 2021a; Tupinambá-Simões et al. 2022; Dias et al., 2020; Dainelli et al. 2021; 2021a).

Assim, o presente projeto teve como objetivo identificar e quantificar resíduos madeireiros pós-colheita florestal com dimensões comerciais (> 3 m de comprimento e > 4 cm de diâmetro) com uso de técnicas de segmentação de imagens de alta resolução espacial oriundas de Aeronave remotamente pilotada, sob dois sistemas de colheitas distintos toras curtas e toras longas numa área de plantio comercial de eucalipto. Acrescido disso, teve como foco central servir como fonte de inovação, e formular uma tecnologia replicável e adaptável a diferentes situações a fim de gerar novas rotas e direcionamentos multidisciplinares ao integrar técnicas do sensoriamento remoto e manejo florestal na gestão de qualidade florestal.

2. REVISÃO DE LITERATURA

2.1 A colheita florestal

2.1.1 Apresentação geral

A colheita compreende um dos componentes principais da produção florestal e tem por objetivo preparar e levar a madeira até o local de transporte para o pátio industrial. Para o planejamento da colheita, há variáveis multidisciplinares envolvidas a fim de obter resultados sustentáveis e viáveis economicamente, que equilibram os aspectos econômicos, sociais e ambientais, ao proporcionar benefícios duradouros para as comunidades, empresas e o meio ambiente (Strang, 1983; Dykstra & Heinrich, 1996; Machado, 2014; Mac Donagh et al. 2017; Poudyal et al. 2018 Marchi et al. 2018; Vasconcelos & Silva Junior, 2021).

Até o beneficiamento da madeira, a colheita é a etapa com maior custo para as empresas florestais, ultrapassando em alguns casos 50% do total das despesas de produção e interfere diretamente na qualidade dos produtos gerados nos processos industriais. O que demandam de novos meios quanto a métodos de aproveitamento e reaproveitamento, redução de custos e eficiência operacional a fim de gerar menos gastos para a companhia (Machado, 2014; Mac Donagh et al. 2017; Diniz et al. 2020).

2.1.2 Sistemas de colheita florestal na geração de resíduos

O sistema de colheita florestal é caracterizado como um conjunto integrado de atividades com finalidade de melhorar a utilização eficiente de recursos humanos e materiais na extração de materiais lenhosos e seus derivados, e garantia de um fluxo contínuo de madeira de forma segura e economicamente viável (Drolet & LeBel, 2010; Machado, 2014). Esse processo envolve discussões abrangentes nos aspectos de segurança do trabalho, técnicos operacionais, silviculturais, ergonômicos, ambientais e sociais.

O objetivo central da organização em sistema de colheita é para evitar possíveis gargalos e déficits na produção e oferta de madeira, na interrupção na cadeia produtiva e suprimento, além da garantia na qualidade e sustentabilidade do processo de colheita florestal (Drolet & LeBel, 2010; Machado, 2014; Häggström & Lindroos, 2016; Poudyal et al. 2018). As principais etapas da colheita florestal que

podem vir a gerar resíduos madeireiros no talhão são: corte (derrubada, desgalhamento, cavaqueamento, descascamento e traçamento); e extração (extração, arraste, empilhamento e carregamento), para posterior transporte da madeira (logística de transferência realizada para o pátio da indústria) (Machado, 2014).

Os sistemas de colheita podem variar de acordo com o estado e forma da matéria prima utilizada em relação ao padrão da empresa, com o local onde é feito as etapas de corte e processamento inicial da madeira, com o grau de mecanização e com o tempo entre corte e carregamento da madeira que é conhecido como quente ou frio (Machado, 2014; Guerra et al. 2016; Junior et al. 2016; Fiedler et al. 2017). Dentre os principais maquinários utilizados nas empresas para a etapa da colheita estão: Harvester, Feller, Feller-Buncher, Forwarder, Slingshot, Skidder, Garra-traçadora, Delimber e demais gruas, e outros tratores e maquinários adaptados ao objetivo-sistema da empresa. No setor florestal brasileiro, cinco sistemas de colheita são usualmente empregados (Machado, 2014; Guerra et al. 2016; Junior et al. 2016; Fiedler et al. 2017; Sanei Bajgiran et al. 2017; Mac Donagh et al. 2017; Miyajima et al. 2021; Oro et al. 2021; Rocha et al. 2022), são eles:

Sistema de toras curtas (Cut-To-Length): mais empregado no País, principalmente no setor da celulose. O Harvester e Forwarder são as máquinas mais utilizados nesse sistema. Devido ao processamento ser todo no local de colheita das árvores, a geração de resíduos se espalha por todo talhão, a depender da qualidade da operação e característica do terreno. Dentre os resíduos mais comuns deste sistema estão as cascas, galhos, copas e toras das árvores com diferentes comprimentos e diâmetros.

Sistema de toras longas-compridas (Tree Length): a árvore é derrubada usando Feller ou Feller-Buncher e apenas semiprocessada (desgalhada e destopada) no local de corte por uma garra traçadora, o que centraliza os feixes de casca e ponteiras numa linha oposta aos feixes de tora. O acabamento da madeira (p.e., descascamento, toragem, seleção-qualificação) é executado na estrada ou em um pátio temporário de processamento. Devido a essa organização, há uma concentração de toras na linha de corte, com toras maiores e com casca ao longo do sentido da linha de corte e da derrubada.

Sistema de árvores inteiras (Full Tree): a árvore é derrubada e extraída para um pátio intermediário ou estrada sem ser desgalhada e traçada. O acabamento da

madeira (desgalha, descascamento, toragem e seleção) é executado na estrada ou em um pátio intermediário de processamento. Os maquinários mais utilizados são Feller ou Feller-Buncher para corte e derrubada, e uma garra traçadora para processamento que vai variar com o emprego da madeira.

Sistemas de árvores completas (Whole Tree): a árvore é arrancada, o qual inclui parte de seu sistema radicular e posterior extraída para a beira da estrada ou pátio temporário, onde é realizado o seu processamento. O emprego do Feller-Buncher para arrancar toda árvore com mais presença de raiz possível, pois em sua maioria das vezes é um sistema adotado em madeiras para biomassa de carvão vegetal, o uso de Skidder para baldeio e garras traçadoras para processamento.

Sistema de cavacos de madeira (Chipping): A árvore é derrubada e pode ser processada no local de derrubada com uso do Feller ou Feller-Buncher ou Harvester, é extraída na forma de cavacos, diretamente para a margem da estrada ou pátio com auxílios de picadores e garra traçadoras para estocagem ou transporte diretamente para pátio da indústria. No geral, há três subsistemas: cavaqueamento integral, cavaqueamento parcial com casca, e cavaqueamento parcial sem casca.

Cada sistema de colheita exerce diferentes impactos na geração dos resíduos florestais, além de influenciar diretamente a fertilidade do solo, o desempenho das máquinas, os custos operacionais da empresa, a disponibilidade de coprodutos e as oportunidades derivadas do aproveitamento desses resíduos (Thiffault et al. 2014; Legout et al. 2020). Kizha & Han, (2016) avaliaram que as etapas da separação e o processamento de resíduos florestais nos talhões aumentam o custo global da operação de colheita florestal em 10%, contudo esse valor foi inferior ao que os resíduos no campo representam para as demais operações e a perda econômica em razão do não aproveitamento do volume de madeira desperdiçado.

2.1.3 Gestão de Qualidade na colheita florestal

A gestão ou controle de qualidade pode ser conceituada como um sistema amplo, complexo e que abrange todas as áreas da empresa, em um esforço comum e cooperativo, a fim de estabelecer, otimizar e assegurar a qualidade da produção e operação, em níveis de viabilidade econômica, além de priorizar as necessidades dos clientes e consumidores (Jacovine et al. 2005; Rotili et al. 2022). O setor florestal competitivo e sustentável busca se diferenciar do ponto de vista da qualidade de seus produtos e processos operacionais sem elevar os custos de produção (Jacovine et al.

1999; Jacovine et al. 2005). Assim, inúmeras ferramentas de gestão da qualidade podem ser empregadas em conjunto de ações nas atividades operacionais de campo na atividade da colheita florestal a depender do tipo de madeira, das equipes responsáveis, do tipo de maquinário e gestão adotada. Logo, as atividades da colheita devem estar integradas, a fim de proporcionar os melhores custos em eficiência e oportunidades para melhoria contínua no desenvolvimento de novos produtos e processos nas operações florestais. Assim, corroborar na gestão das operações, reduzir riscos de falhas e auxiliar as organizações na tomada de decisões em tempo hábil para atingir seus objetivos (Silva Oliveira et al. 2019).

Do ponto de vista histórico, a adoção da gestão de qualidade no setor florestal ocorreu de forma gradual em comparação com outros setores. O primeiro modelo surgiu na década de 80, seguido por um segundo modelo na década de 90 (De Freitas et al., 1980; Trindade, 1993). Atualmente, observa-se um aumento significativo do interesse nessa abordagem, impulsionado por diversas razões, tais como as necessidades dos clientes, a competição internacional decorrente da ampla disponibilidade de produtos no mercado, o alinhamento com os Objetivos de Desenvolvimento Sustentável (ODS) estabelecidos pelas Nações Unidas, conforme destacado no relatório do IBA (2023 e 2023a), a busca por redução de custos operacionais e o aprimoramento da qualidade do produto.

Na atualidade, a maioria das empresas florestais reconhece as oportunidades de melhoria contínua nos processos produtivos, resultantes da implementação de técnicas de gestão da qualidade em todas as etapas das operações, desde a silvicultura até a colheita, logística e outras atividades relacionadas (Jacovine et al., 1999; Jacovine et al., 2005; Vasconcelos & Silva Junior, 2021; IBA, 2023; 2023a). Essa tendência reflete o compromisso crescente do setor florestal com a eficiência operacional, a excelência no atendimento ao cliente e a sustentabilidade ambiental.

A gestão da qualidade na colheita florestal acontece, principalmente, na aplicação de ferramentas de acompanhamento e controle dos processos em tempo real da operação, com intuito de fomentar a inovação frente a melhorias contínuas, seja em ações preventivas, corretivas ou paliativas, para curto e longo prazo nas operações florestais (Sowa, 2014; Oliveira et al. 2020). Os indicadores da gestão de qualidade estão baseados em quatro pilares: avaliação, prevenção e presença de falhas internas ou externas, que fomentam os planos de ações das atividades na

colheita florestal, com a garantia de conformidade em suas atividades operacionais de campo (Oliveira et al. 2020; Rotili et al. 2022).

Contudo, a melhoria das operações de colheita só pode ser obtida se houver um sistema de controle de qualidade integrado e implementado na empresa como valor cultural (Jacovine et al. 2005). O que, demanda um planejamento horizontal constante dentre os setores da colheita florestal, como citados nos seguintes estudos de: Drolet & LeBel, (2010), Häggström & Lindroos, (2016), Spinelli et al. (2019), Visser & Obi, (2021). Além disso, estudos apontam que, qualquer inferência nos custos da colheita, seu impacto na receita é inversamente proporcional, ou seja, diminui consideravelmente o percentual de custo no valor final da madeira em mais de 10%, sendo eles: Grasso, (1998), Augustynczik et al. (2016), Silva et al. (2016), Ferreira et al. (2018), Simioni et al. (2018), Sales et al. (2019), Santos et al. (2019), Gama et al. (2022), e outros.

Associado a isso, a avaliação dos resíduos madeireiros nas atividades pós-colheita florestal tem fundamental importância, pois permite identificar as principais áreas, módulos de corte e ou materiais genéticos que apresentam uma predisposição desse desperdício (Rotili et al. 2022).

2.2 Geotecnologias

2.2.1 Sensoriamento remoto

O Sensoriamento Remoto é a área do conhecimento em que são estudados métodos para obter informações dos objetos, áreas ou fenômenos por meio de dados adquiridos de sensores, os quais não devem ter contato direto para com o objeto, área ou fenômeno; ou seja, obter imagens e dados a distância (Hunt Jr & Daughtry, 2018; Woodcock et al. 2020; Wellmann et al 2020; Piovan, 2020; Dupuis et al. 2020; INPE, 2023). Os sensores podem ser agrupados em passivos ou ativos, sensores imageadores ou não imageadores; sistema de varredura, quadro ou fotográfico (INPE, 2023).

As informações obtidas pelas imagens desses sensores estão interligadas aos atributos e distintas bandas espectrais (comprimentos de onda), radiância, resoluções radiométricas, temporais ou espaciais que interage de acordo com alvos sob diferentes composições-óticas, como por exemplo: na vegetação, solo, água, edificações, dentre outros (Piovan, 2020). Tais dados são importantes para as etapas do Processamento Digital das Imagens – PDI, com objetivos de aprimorar a qualidade

dos dados e imagens; automatizar processos; integrar dados; facilitar a interpretação das imagens; modelar produtos e coprodutos de interesse, sob os pilares econômicos, sociais, ambientais e científicos do usuário e instituição responsável (Hengl, 2019; Woodcock et al. 2020; Piovan, 2020; INPE, 2023).

2.2.2 Uso de aeronave remotamente pilotada para coleta de imagens

Os Veículos aéreos não tripulados, ou Aeronave Remotamente Pilotada, são alternativas vantajosas para levantamentos, monitoramentos e mapeamentos de ecossistemas de forma remota em estudos de escala detalhada. Atualmente o uso desse equipamento permite o monitoramento responsivo, imediato, oportuno e mais “econômico” de fenômenos como da identificação dos resíduos pós-colheita nos talhões de plantio florestal (Zhang et al. 2016; 2016a). O tipo e tamanho da aeronave remotamente pilotada varia com o uso da pesquisa e sensor embarcado, contudo algumas partes são essenciais para seu bom funcionamento e coleta de informações, como: bateria, motor, asas, controlador eletrônico de velocidade (ESC-Electronic Speed Controller), placa controladora (GPS e giroscópio), câmera, sensores, Ailerons, Elevadores, Leme, carga útil e trem de pouso.

Atualmente são desenvolvidas pesquisas científicas em diferentes áreas do conhecimento e objetivos, como: diagnose ambiental, manejo e capacidade do uso da terra, detecção e monitoramento de desmatamento ambiental e mudança climática, desenvolvimento e aprimoramento do pensamento espacial (mapeamento de áreas, contribuição para obtenção de agricultura sustentável, mapeamento do risco de ocorrência de incêndios florestais, estimativa e dinâmica da biomassa, estoque de carbono, atividades relacionadas ao inventário florestal, colheita e transporte florestal; dentre inúmeros outros (Zhang et al. 2016; 2016a; Santos & Faria, 2017; Braz et al., 2017; Bargos & Matias, 2018; Talbot et al. 2018; Hunt Jr & Daughtry, 2018; Embrapa, 2019; Zgraggen, 2019; Dias et al., 2020; Bourgoin et al. 2020; Sun et al. 2021; Dainelli et al. 2021; 2021a; Tupinambá-Simões et al. 2022).

Acrescido disso, o emprego do Aeronave remotamente pilotada para obter imagens de alta resolução espacial tem fundamental importância no planejamento das atividades da colheita florestal, com finalidade de aumentar o rendimento operacional e de produtividade (Baena et al. 2018; Wu et al. 2019; Windrim et al. 2019; Marra et al. 2021; Tanut et al. 2021; Ferreira et al. 2021).

As aeronaves remotamente pilotadas oferecem vantagens significativas devido à sua habilidade de voar em altitudes mais baixas em comparação com plataformas orbitais. Isso resulta na aquisição de imagens com resolução espacial muito alta, variando de 0,5 a 10 centímetros numa maior resolução temporal. Essa capacidade possibilita a coleta eficiente de dados de plantas e animais, fornecendo destaques valiosos sobre suas interações com o ambiente. Além disso, as aeronaves remotamente pilotada demonstram eficácia notável na detecção e medição de propriedades no dossel da floresta, bem como na identificação de resíduos madeireiros no talhão (Zhang et al. 2016; 2016a). Em suma, os Aeronave remotamente pilotada equipados com sensores de câmera atuam em áreas remotas de difícil acesso, o que tornam ainda mais vantajoso quanto ao seu uso (Piovan, 2020).

Entretanto, para garantir a conformidade legal e a segurança durante missões ou voos com aeronaves remotamente pilotadas, é essencial seguir as regulamentações estabelecidas por instituições como a Agência Nacional de Aviação Civil (ANAC) e a Agência Nacional de Telecomunicações (ANATEL). Isso inclui a obtenção de autorizações de voo do Departamento de Controle do Espaço Aéreo (DECEA) e do Sistema de Acesso de Aeronaves Remotamente Pilotadas (SARPAS/RPAS), além do cumprimento de normas específicas e da elaboração de um manual de voo detalhado. Paralelamente, é crucial realizar uma avaliação de riscos abrangente antes de cada operação, considerando fatores como condições meteorológicas, presença de obstáculos e potenciais interferências. Além disso, é obrigatório contratar um seguro RETA para cobrir eventuais danos a terceiros durante a atividade, garantindo a conformidade legal e protegendo tanto os operadores quanto o público em geral (ANAC, 2022; ANATEL, 2022; DECEA, 2022; 2022a).

2.3 Classificação de imagens digitais

2.3.1 Técnicas de classificação de imagens

A classificação de imagens no sensoriamento remoto refere-se ao processo de obtenção de rótulos ou categorias específicas para diferentes partes de uma imagem obtida por sensores remotos. Esse procedimento envolve a aplicação de técnicas para identificar e separar áreas ou objetos com características semelhantes, permitindo a interpretação e análise dos elementos presentes na cena capturada pelo sensor. A classificação de imagens é uma etapa crucial na seleção de informações específicas

a partir de dados de sensoriamento remoto, o que possibilita o entendimento e monitoramento de diversas informações na superfície terrestre (Haralick et al. 1973; Lu & Weng, 2007; Abburu & Golla, 2015; Ma et al. 2017; Lv & Wang, 2020; Imani & Ghassemian, 2020; Bhojanapalli et al. 2021).

Este processo é essencial para a interpretação e análise de dados obtidos por sensoriamento remoto. Atualmente, destacam-se diversas abordagens para a classificação de imagens incluindo: Não supervisionada, Semi supervisionada, Supervisionada, Aprendizado Profundo, Híbrida (junção de metodologias), Análise orientada ao objeto, ou Fotointerpretação (Figura 01). Essa variedade de métodos reflete a complexidade e diversidade de aplicações na interpretação de imagens.

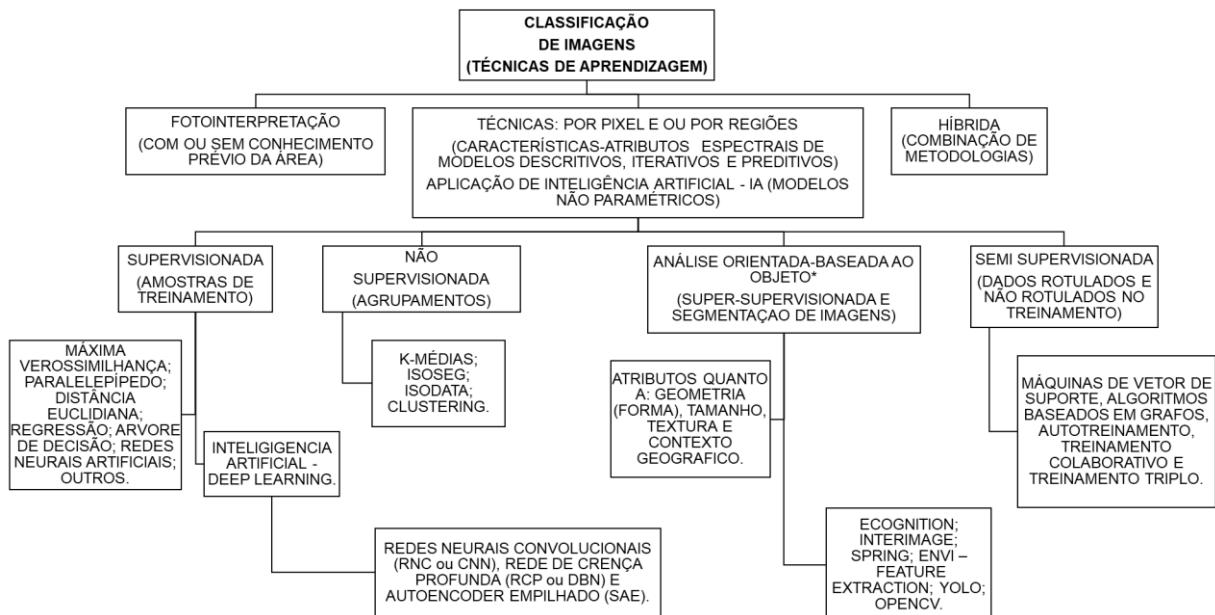


Figura 01: Tipos de classificações de imagens e as subdivisões quanto às técnicas, diferenciações e principais algoritmos ou ferramentas utilizados. Fonte: Autor, (2023), adaptado de (Haralick et al. 1973; Lu & Weng, 2007; Abburu & Golla, 2015; Ma et al. 2017; Lv & Wang, 2020; Imani & Ghassemian, 2020; Bhojanapalli et al. 2021).

Há dois principais tipos de classificadores: **por pixel** que avalia pixels homogêneos por meio de probabilidades, distâncias e critérios de avaliação, subdivididos em estatísticos e determinísticos e **por região** que considera agrupamentos de pixels como unidade de trabalho com características semelhantes-homogêneas. De forma geral, o tipo de classificação é definido por alguns fatores, como: o objetivo do usuário, a escala do local de estudo, a condição econômica da

empresa/grupo e as habilidades técnicas-científicas do analista (Lu & Weng, 2007; Lv & Wang, 2020).

2.3.1.1 Fotointerpretação e os processos de classificação

A fotointerpretação cabe principalmente da experiência do profissional seja no conhecimento prévio ou detalhado da área, quanto da técnica-científica correspondente as ferramentas do sensoriamento remoto disponíveis e de seus atributos estatísticos. É uma das principais etapas da classificação de imagens, quando se possibilita aplicar uma validação de campo em sua técnica empregada.

Contudo, a forma de avaliação-validação dos processos de classificação se baseia principalmente na Verdade de campo versus a classificação final (imagem ou mapa da área), contudo, alguns fatores estatísticos ligados a acurácia e precisão são importantes, como: percentual de erro, matriz confusão, índice kappa, índice de desempenho geral e por classe (omissão e comissão), dentre outros que facilite o entendimento do modelo estabelecido (Lu & Weng, 2007; Foody, 2008; Lv & Wang, 2020).

Ainda referente a avaliação da classificação automática, os autores Cihlar et al. (1998) e De Fries e Chan (2000) propuseram alguns critérios fundamentais que devem satisfazer (quando aplicável e requerido), sendo eles: reproduzibilidade, robustez aos ruídos nos dados do treinamento, precisão, estabilidade do algoritmo, aplicabilidade uniforme, capacidade de utilizar plenamente o conteúdo informacional dos dados, e objetividade. Além disso, para uma boa classificação deve-se observar a forma de obtenção e seleção dos dados coletados pelos sensores.

2.3.1.2 Classificação não supervisionada

A classificação de imagem não supervisionada pode ser considerada a técnica mais indicada quando não se tem conhecimento prévio do local de pesquisa. Inicialmente o algoritmo agrupa os pixels em “clusters” com base em suas propriedades e características espectrais. Em seguida, classifica cada cluster com uma classe de uso e cobertura do solo que tenha características “semelhantes” (Paoli et al. 2009; Jian, 2012; Dhingra & Kumar, 2019; Lv & Wang, 2020). Os algoritmos mais comuns são os ISODATA, e K-média.

2.3.1.3 Classificação supervisionada

Na classificação supervisionada, seleciona-se amostras representativas para cada classe de uso e cobertura do solo, assim, os algoritmos então utilizam esses “sítios de treinamento” as amostras de treinamento e os aplica à imagem inteira para gerar o produto classificado, baseado nas avaliações estatísticas dos atributos selecionados. Logo, para esse tipo de classificação faz-se necessário ter conhecimento profundo do algoritmo e métricas selecionadas ou conhecimento prévio da região estudada (baseado em campo ou literatura), a fim de conhecer as principais características da vegetação e solo, para auxiliar na divisão e definição de fronteiras entre as classes de amostragem e validação, a fim de diminuir erros e incertezas na classificação.

As três etapas básicas principais para se ter essa classificação são: selecionar as amostras de treinamento, gerar um arquivo de assinatura (base) que é responsável por armazenar todas as informações e combinações espectrais para as amostras de treinamento, calibrar o modelo e classificar (Tuia et al. 2011; Zhang et al. 2016; 2016a; Jiang et al. 2016; Sima et al. 2018; Dhingra & Kumar, 2019; Lv & Wang, 2020). Os algoritmos mais comuns são: Máxima Verossimilhança, Regressão, Árvore de Decisão, dentre outros.

Acrescido disso, atualmente as técnicas da aprendizagem profundo (Deep Learning), vêm sendo amplamente difundidas dentre os algoritmos supervisionados, com técnicas de aprendizado profundo derivados de uma Inteligência Artificial mais robusta e complexa, como o Yolo (Zhang et al. 2016; 2016a; He et al. 2019; Li et al. 2019; Mou et al. 2020; Lv & Wang, 2020; Bhojanapalli et al. 2021).

2.3.1.4 Classificação semi supervisionada

A classificação semi-supervisionada surge como alternativa de suprir as demandas e “erros” gerados pela supervisionada e não supervisionada. Pois nela são utilizados dados rotulados e não rotulados durante o treinamento do classificador, assim compensa a falta de aprendizado do não supervisionado (falta de conhecimento prévio entre a relação das categorias agrupadas e reais) e do supervisionado (quando têm poucas amostras para os rótulos das classes).

Assim, esse método de classificação é baseado em amostras de dados rotulados (pequena quantidade) e não rotulados no espaço de características, como forma de buscar melhor precisão nos resultados. Utiliza-se as máquinas de vetor de suporte, algoritmos baseados em grafos e autotreinamento, treinamento colaborativo

e treinamento triplo (Krishnapuram et al. 2004; Wang et al. 2015; Han et al. 2015; Yanping et al. 2015; Kipf & Welling, 2016; Lv & Wang, 2020; Wang & Du, 2021).

2.3.1.5 Classificação orientada ao objeto - OBIA

Na classificação orientada ao objeto - OBIA, o foco principal é gerar objetos segmentados com geometrias e características semelhantes, por meio de agrupamento de pixels (regiões), logo, não há pixels únicos, assim, indica-se trabalhar com imagens de alta resolução, pois possibilita maior detalhamento da área (Blaschke, 2010; Powers et al. 2012; Arvor et al. 2013; Blaschke et al. 2014; Ma et al. 2017). As características que auxiliam na diferenciação dos objetos são:

Geometria ou forma: classifica objetos de acordo com geometrias pré-determinada ou uma estatística de forma, ou seja, testa a geometria de um objeto com a forma mais próxima que ele possui.

Textura: pode ser de acordo com sua textura, que é a homogeneidade de um objeto.

Espectral: um dos principais utilizados, pois se usa o valor médio das propriedades espectrais, como, infravermelho próximo, infravermelho de onda curta, vermelho, verde ou azul – RGB, dentre outras combinações espectrais disponíveis.

Contexto e características geográficos: também pode ser considerado o contexto que estão empregados, ou seja, tais objetos têm relações de proximidade e distância entre vizinhos, assim se define características que podem ser utilizados nessa classificação.

Na classificação OBIA, alguns algoritmos e bibliotecas são mais utilizados e ou já estão em maiores etapas de desenvolvimento, sendo eles: eCognition, Yolo, OpenCV, DeepForest, dentre outros. A segmentação pode variar de acordo com a técnica escolhida e subdividida em três grandes grupos, entretanto é essencial determinar a escala de segmentação apropriada a fim de obter resultados de segmentação otimizados e condizentes com a área avaliada, são eles:

Baseada em descontinuidade: nessa técnica ela divide a imagem ao considerar as mudanças abruptas ou discrepantes (nos níveis de cinza), que pode ser feito através de uma matriz de convolução, que são responsáveis por detectar pontos isolados, bordas e linhas do objeto.

Baseada em similaridade: já nesta o que é levado em consideração é o interior dos objetos, ou seja, analisa as propriedades similares nos pixels que pode

ser feito por: crescimento de regiões (responsável por agregar regiões-pixels vizinhos até não haver mais possibilidades, os quais possuem características similares), limiarização (neste já é realizado uma discretização dos dados-objetos por meio de histogramas, os quais possuem limiares de 1 ou 0, para separar objetos), detecção de bacias (esse utiliza de técnicas de ambos os métodos anteriores, pois ele detecta bordas e agrupa regiões, o resultado é semelhante a um modelo digital de elevação e o limiar é definido pelo usuário, em que os objetos são criados), pirâmides (método mais radical, pois o algoritmo divide a imagem trabalhada em quadrantes arbitrários por meio da identificação dos pixels, em que são reconhecidos os objetos da imagem) e clustering (quando ocorre uma conversão da imagem em atributos (valores-pontos), e os objetos são definidos justamente pela separação das nuvens de pontos, a forma como se separa os agrupamentos são variados como o K-MÉDIAS).

Baseada em objeto (multi resolução): nesse método a imagem pode ser segmentada sob diferentes características como sua forma, compacidade, suavidade, bordas, espectro, entorno (pixels vizinhos), dentre outros. O limiar (escala do objeto) é definido pelo usuário, em que a cor e forma define sua uniformidade e a escala seu tamanho.

Acrescido disso, quando se tem imagens de baixa a média resolução espacial, tanto as técnicas tradicionais de classificação por pixel quanto em OBIA exercem muito bem suas respectivas funcionalidades dentro do contexto imposto, porém, quando se combinado uma imagem de altíssima resolução espacial, a OBIA é mais indicada, pois reduz o erro de identificação das classes (Cleve et al. 2008; Myint et al. 2011; Addink et al. 2012; Tehrany et al. 2014; Blaschke et al. 2014).

O contexto histórico do desenvolvimento das técnicas de Análise de Imagens Baseada em Objetos (OBIA) remonta ao início dos anos 2000, quando começou a ser intensivamente explorada. Desde então, houve um aumento significativo no interesse por essa abordagem, impulsionado não apenas pela evolução contínua dos sensores de imagem, tanto orbitais quanto terrestres, mas também pela crescente disponibilidade e diversidade de dados gerados por esses sensores. A proliferação desses dados, combinada com avanços na linguagem de programação e nas técnicas de inteligência artificial, tem estimulado um aprofundamento dos estudos e uma ampla aplicação da OBIA em diversos campos, incluindo universidades e empresas do setor geoespacial.

Essa convergência de fatores tem contribuído para a consolidação da OBIA como uma ferramenta poderosa para análise e interpretação de imagens, impulsionando sua adoção e desenvolvimento em várias áreas das geotecnologias (Blaschke & Strobl, 2001; Lu & Weng, 2007; Blaschke, 2010; Ma et al. 2017; Imani & Ghassemian, 2020). Com isso a técnica OBIA só vem a ganhar espaço no cenário Internacional e Nacional nas atividades da engenharia florestal (Ma et al. 2017), principalmente quando se observa o atual cenário brasileiro das indústrias florestais.

2.4 Técnicas de segmentação e detecção de objetos

2.4.1 Biblioteca OpenCV – conceituação

A utilização de geotecnologias em conjunto com softwares de automação computacional ganha destaque crescente nas pesquisas brasileiras. Esse destaque é atribuído à sua aplicabilidade versátil, capacidade de reprodução dos resultados, robustez das soluções propostas e à natureza do código aberto, o que possibilita sua implementação em diversas áreas de estudo.

O R e Python emergem como escolhas proeminentes no setor florestal. Essa preferência se justifica devido a vários motivos, como a sua capacidade de incorporar e adaptar uma ampla gama de funções e bibliotecas gratuitas da linguagem de programação, inclusive de sua multidisciplinaridade e diversidade nas funcionalidades quanto às funções e pacotes disponíveis. Além disso, são amplamente empregados em empresas do setor florestal. Sua utilização promove o aprimoramento da produtividade, sustentabilidade e eficácia dos processamentos de dados, notadamente aqueles provenientes de imagens capturadas por Aeronave remotamente pilotada. A colaboração para o desenvolvimento conjunto e a ênfase na ciência de dados reproduzível e adaptável, de acesso aberto, são características adicionais que consolidam a posição desses softwares como pilares fundamentais no contexto florestal e demais setores industriais (R, 2023; Python, 2023).

Nesse sentido, o OpenCV - Open Source Computer Vision Library (OpenCV; 2023), como biblioteca de linguagem computacional e aprendizado de máquina de código aberto, veio para fornecer uma infraestrutura aplicável e revolucionária para diversos aplicativos de visão computacional além de acelerar o uso da percepção do algoritmo nos produtos e/ou objetos da imagem. É um produto licenciado Apache 2.0 que o torna sua utilização e modificação de código pelas empresas mais fácil e iterativa. Devido a gama de possibilidades de algoritmos do OpenCV, são utilizados

para detectar e reconhecer rostos, identificar e detectar objetos, classificar ações humanas em vídeos, rastrear movimentos de câmeras, rastrear objetos estáticos e em movimento, dentre outros (OpenCV; 2023).

Ao considerar a previsão da biblioteca OpenCV na detecção de objetos, foi escolhido para realizar o reconhecimento de resíduos madeireiros pós-colheita florestais que pode se destacar diante das atividades de identificação, localização e mensuração das toras remanescentes no talhão. As utilidades e aplicabilidades do OpenCV são evidentes, pois oferece interfaces para C++, Python, Java e MATLAB, o que abrange uma ampla gama de linguagens de programação. Além disso, sua compatibilidade com sistemas operacionais como Windows, Linux, Android e Mac OS confere-lhe uma aplicabilidade robusta em diferentes ambientes de desenvolvimento.

2.4.2 Biblioteca OpenCV – Detecção de bordas (*Canny*)

O algoritmo Canny Edge Detection é utilizado para detecção de bordas, desenvolvido pelo pesquisador por John F. Canny in (OpenCV, 2023a). A etapa de detecção de bordas é uma técnica crucial para extrair informações estruturais úteis de diferentes objetos de visão que compõem a imagem, além de reduzir drasticamente a quantidade de dados a serem processados, por vir a aumentar a eficiência de detecção de formas geométricas contidas na imagem. Para compreender seu funcionamento deve-se subdividir em alguns estágios (já intrínsecos ao código), sendo eles:

Redução de ruído: Como a detecção de bordas é suscetível a ruído na imagem devido a sua resolução, o primeiro passo é remover-reduzir o ruído existente com aplicação do filtro gaussiano 5x5, mas pode variar de acordo com a aplicabilidade do modelo.

Gradiente de Intensidade de borda na Imagem: A imagem suavizada é então filtrada com um kernel Sobel na direção horizontal e vertical para obter a primeira derivada na direção horizontal (G_x) e direção vertical (G_y). Assim, por meio dessas duas imagens, podemos encontrar o gradiente de borda e a direção de cada pixel, da seguinte forma (equações abaixo):

$$\text{Eq1. } G = \sqrt{G_x^2 + G_y^2}$$

Em que:

G_x = direção horizontal;

G_y = direção vertical;

G = Gradiente de Borda

$$\text{Eq2. } \theta = \tan^{-1} \left(\frac{G_y}{G_x} \right)$$

Em que:

θ = ângulo dos gradientes;

De forma geral, a direção do gradiente é sempre perpendicular às arestas, e é arredondado para um dos quatro ângulos que representam as direções vertical, horizontal e duas diagonais, o que auxilia nessa diferenciação das bordas para os agrupamentos de pixels e cada pixel, cada aresta gera um ângulo de inclinação o que define o direcionamento da borda.

Supressão não máxima ou limiar de magnitude de gradiente: Após obter a magnitude e a direção do gradiente na imagem, uma varredura completa é realizada a fim de remover quaisquer pixels indesejados que possam não constituir a borda. Para tal, cada pixel, é verificado se é um máximo local em sua vizinhança na direção do gradiente, ou não, (Figura 02). Sendo que, o ponto A está na borda (na direção vertical), em que a direção do gradiente é normal à borda. Já os pontos B e C estão em direção ao gradiente. Assim, o ponto A é analisado por meio dos pontos B e C para possibilidade de se formar um máximo local, se afirmativo, é considerado para o próximo estágio, caso contrário, é suprimido (colocado em zero), logo, o resultado obtido das bordas é uma imagem binária com "bordas suaves" detectadas:

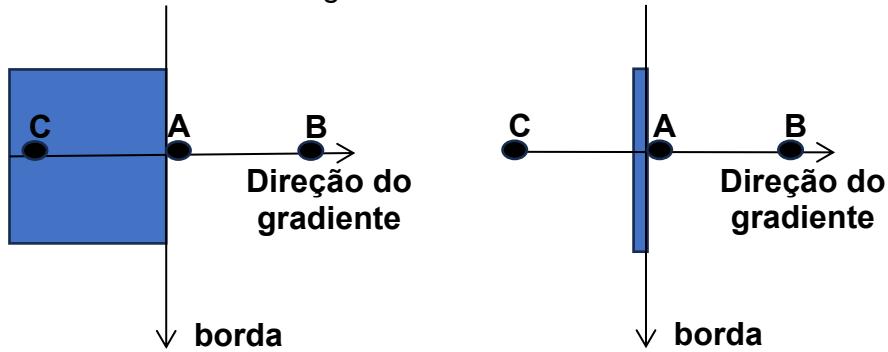


Figura 02: Ilustração da direção do gradiente para a definição e constituição do que é a borda no objeto. Fonte: OpenCV, (2023a)

Limite de Histerese ou limite duplo: Neste estágio decide quais são arestas-linhas e quais não são, e para isso, precisa-se de dois valores limites, minVal e maxVal . Em que, para qualquer aresta com gradiente de intensidade maior que maxVal certamente são arestas e aquelas abaixo de minVal certamente não são arestas, portanto, serão descartadas. Para aqueles que estão entre esses limiares são classificados como arestas ou não arestas baseadas em sua conectividade. Logo, se estiverem conectados a pixels de "borda segura", eles são considerados parte das bordas, contrário são descartados (Figura 03).

Em que, a borda A está acima do maxVal , portanto considerada como "certa". Embora a aresta C esteja abaixo de maxVal , ela está conectada à aresta A, de modo que também é considerada uma aresta válida e obtém-se a curva completa. Porém, a aresta B, embora esteja acima de minVal e esteja na mesma região que a aresta C, não está conectada a nenhuma "aresta segura", de modo que será descartada. Portanto, é muito importante selecionar minVal e maxVal de acordo para obter o resultado correto, um parâmetro que pode variar com a imagem base, objetivo do trabalho, qualidade da coleta de dados, e visualização final das bordas. Nesse estágio também remove pequenos ruídos de pixels na suposição de que as bordas são linhas longas e seguras.

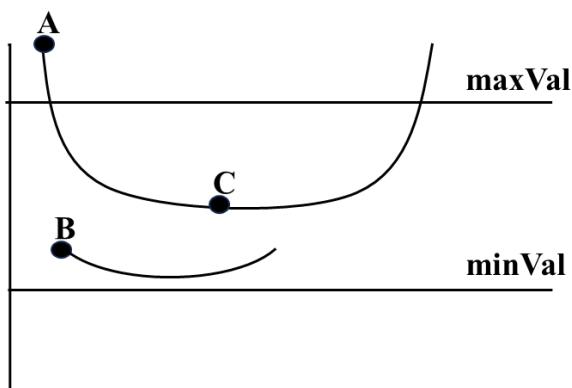


Figura 03: Ilustração da composição de quais serão arestas-linhas e quais não, sob a ótica dos valores limites, minVal e maxVal . Fonte: OpenCV, (2023a)

2.4.3 Biblioteca OpenCV – Detecção de geometria

A aplicação da transformada de HoughLinesP da scikit-image utilizado pela biblioteca OpenCV para detecção das linhas após realce das bordas e segmentação dos objetos de interesse (Jiri Matas et al., 2000), com finalidade de exibir linhas retas

(geometria lineares) de uma imagem de aresta binária de entrada (edges). Sabe-se que geralmente as linhas são parametrizadas como $y = mx + c$, com gradiente "m" e interceptação "y c", no entanto, isso significaria que "m" vai ao infinito para linhas verticais. Assim para evitar isso, o algoritmo constrói um segmento perpendicular à linha, levando à origem, o qual a linha é representada pelo comprimento desse segmento, "r" e o ângulo que ele faz com o eixo x, θ (HoughLineP, 2023; HoughLines, 2023).

Logo, a transformada de Hough constrói uma matriz de histograma representando o espaço de parâmetros, "M x N", para "M" diferentes valores do "r" e "N", valores diferentes de θ . Dessa forma, para cada combinação de parâmetros, "r e θ ", tem-se o número de pixels diferentes de zero na imagem de entrada que cairia perto da linha correspondente e incrementamos a matriz na posição (r, θ) , o que evita linhas infinitas, a determinar inclinação e limites de ocorrência.

Dessa forma, para cada pixel diferente de zero "tendenciando" para possíveis candidatos de linha, e os máximos locais no histograma resultante indicam os parâmetros das linhas mais prováveis detectados na imagem. Para incrementar essa funcionalidade tem-se a Transformada Hough Probabilística Progressiva, o qual diz que, as linhas podem ser extraídas durante o processo de votação caminhando ao longo dos componentes conectados, o que retorna o início e o fim de cada segmento de linha. Para tal, o algoritmo possui três parâmetros principais: um limite geral que é aplicado ao acumulador Hough, um comprimento mínimo de linha (threshold) e a lacuna de linha (line_length) que influencia a fusão de linha, parâmetros que variam com a aplicação e qualidade da imagem gerada (Duda & Hart, 1972; Galamhos et al. 1999).

3. MATERIAIS E MÉTODOS

3.1 Área de estudo

O estudo foi conduzido em duas áreas específicas de plantios comerciais de eucalipto localizadas no estado de São Paulo, Brasil, (Figura 04). Ambas as regiões exibem características predominantemente plano e suave onulado (EMBRAPA, 2023), típicos da paisagem central do Estado. Com base em dados climáticos oficiais da EMBRAPA (2023a) do Estado, essas áreas são conhecidas por apresentar

variações sazonais distintas, sendo o clima tropical de altitude, que, segundo a classificação de Koeppen, é o Cwa, clima quente com inverno seco e períodos de precipitação moderada, fatores que influenciam diretamente no ciclo de crescimento das árvores, com uma média anual de precipitação de aproximadamente 1.400 milímetros e temperatura média anual em torno de 27°C. Quanto ao solo, segundo a classificação proposta no Sistema Brasileiro de Classificação de Solos (SiBCS) a região estuda apresenta uma variação de Latossolos Vermelhos, Vermelho-Amarelos Distróficos e Areias Quartzosas sobre as rochas do Grupo Bauru e os sedimentos terciários (EMBRAPA, 2023).

Além disso, a topografia levemente ondulada dessas áreas tem impacto direto na escolha dos sistemas de colheita adotados. Na Área A (Figura 4), de 17 hectares, onde o sistema de Toras Curtas é implementado, observa-se o uso de Harvester, para as etapas do corte e pré-processamento das árvores, e Forwarder, que são empregados para o baldeio e empilhamento de toras. Por outro lado, na Área B (Figura 4), de 16 hectares, onde se adota o sistema de toras longas, são utilizados Feller e garras traçadoras de toras, que lidam de forma mais eficiente com a manipulação de toras de maior comprimento. Esses sistemas de colheita demonstram diferenças marcantes na geração de resíduos, sendo essencial considerar esses fatores ao avaliar as operações de colheita e suas implicações no manejo de resíduos florestais.

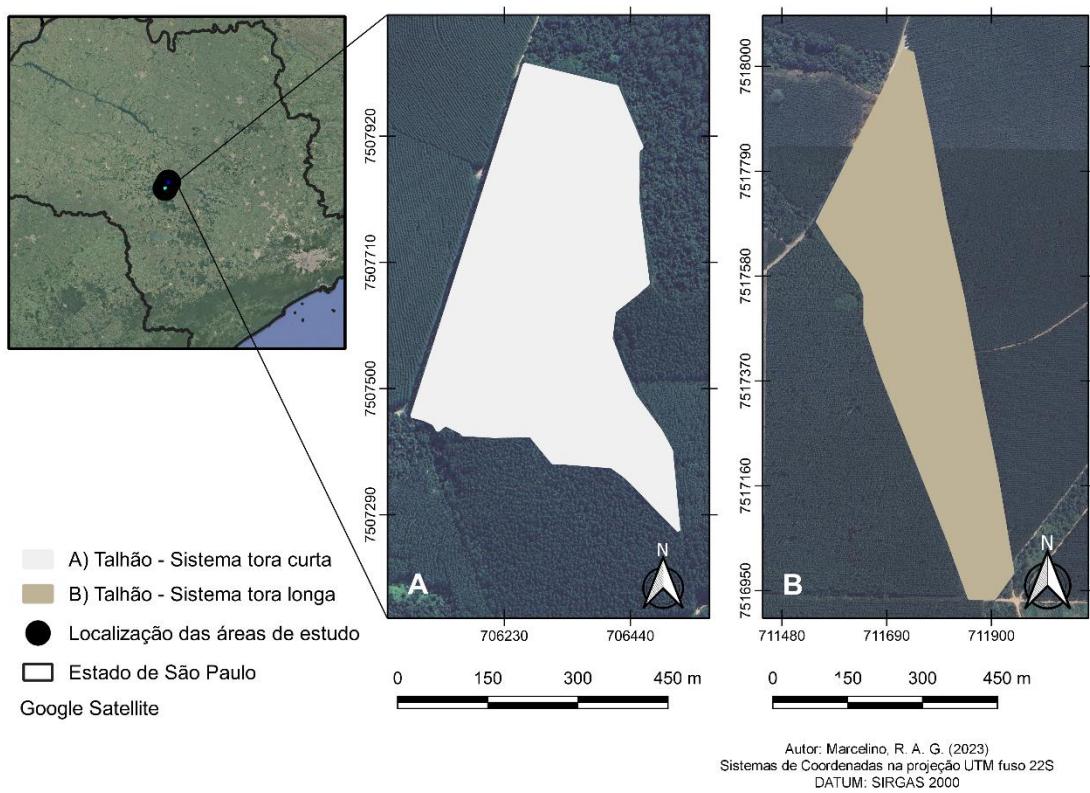


Figura 04: Localização dos talhões onde foram coletados os dados de resíduos madeireiros pós-colheita florestal, sob os cenários avaliados. Fonte: Autor, (2023).

3.2 Aquisição das imagens (Ortomosaico)

A aquisição das imagens foi realizada por meio de sobrevoos de Aeronave remotamente pilotada nos respectivos talhões após a fase de colheita florestal, quando as toras já haviam sido baldeadas e ou transportadas, para isso foram demarcados os pontos de controle fisicamente no terreno com objetos claramente visíveis e identificáveis (placas refletivas) de onde foram os pontos de partida do voo. As imagens, ortomosaico, capturadas contêm informações em RGB e com resoluções espaciais distintas, definidas em função de três alturas de voo. Para garantir a qualidade das imagens, foram considerados planos de voo com uma velocidade média de 7 m/s, com uma sobreposição frontal de 80% e uma sobreposição lateral de 75% usando o modelo Phantom 4 Pro da DJI de 40 megapixel para tora curta e Mavic 2 Pro da DJI de 12 megapixel para tora longa. Assim, foi estabelecido um protocolo de coleta para possibilitar a comparação dos resultados obtidos após o processamento das imagens dos Aeronave remotamente pilotada, Tabela 01.

Tabela 01: Descrição dos atributos de coletas de acordo com o sistema adotado a fim de obter variação de dados para o algoritmo.

Atributos da coleta	Toras curtas – Área A	Toras longas – Área B
Período do voo	09 a 15h	09 a 15h
Altura do voo	60, 90 e 120 m	40, 60 e 80 m
Ortomosaico -		
Resolução espacial (pixel)	0,8 – 1,2 – 1,5 cm	1,1 – 1,8 – 2,5 cm
Toras	Sem casca	Com casca
Tempo pós-colheita (corte + baldeio)	30 dias	40 dias

O objetivo primordial desta etapa foi garantir a aplicabilidade e reproduzibilidade do modelo em diversas situações de campo no setor florestal. Considera-se o impacto nas operações, bem como possíveis variações volumétricas, como sendo resultantes das condições específicas de cada sistema testado.

3.3 Levantamento de campo

A validação de campo, constitui na alocação e distribuição de forma aleatória de parcelas circulares de 400 m² com raio de 11,28 m, nas áreas de estudo, de acordo com a proporção 1:1 ha da área total de cada sistema (Figura 05), ou seja, a cada 1 hectare de área foi lançado uma parcela aleatória. A marcação e numeração dos resíduos em campo foram realizadas antes do sobrevoo com Aeronave remotamente pilotada, para posterior identificação nas imagens, conforme demarcado nos pontos centrais de cada parcela. Em algumas situações, as toras foram identificadas com spray e, quando possível, marcadas com sacos plásticos, (Figura 06), proporcionando uma validação robusta dos resultados obtidos.

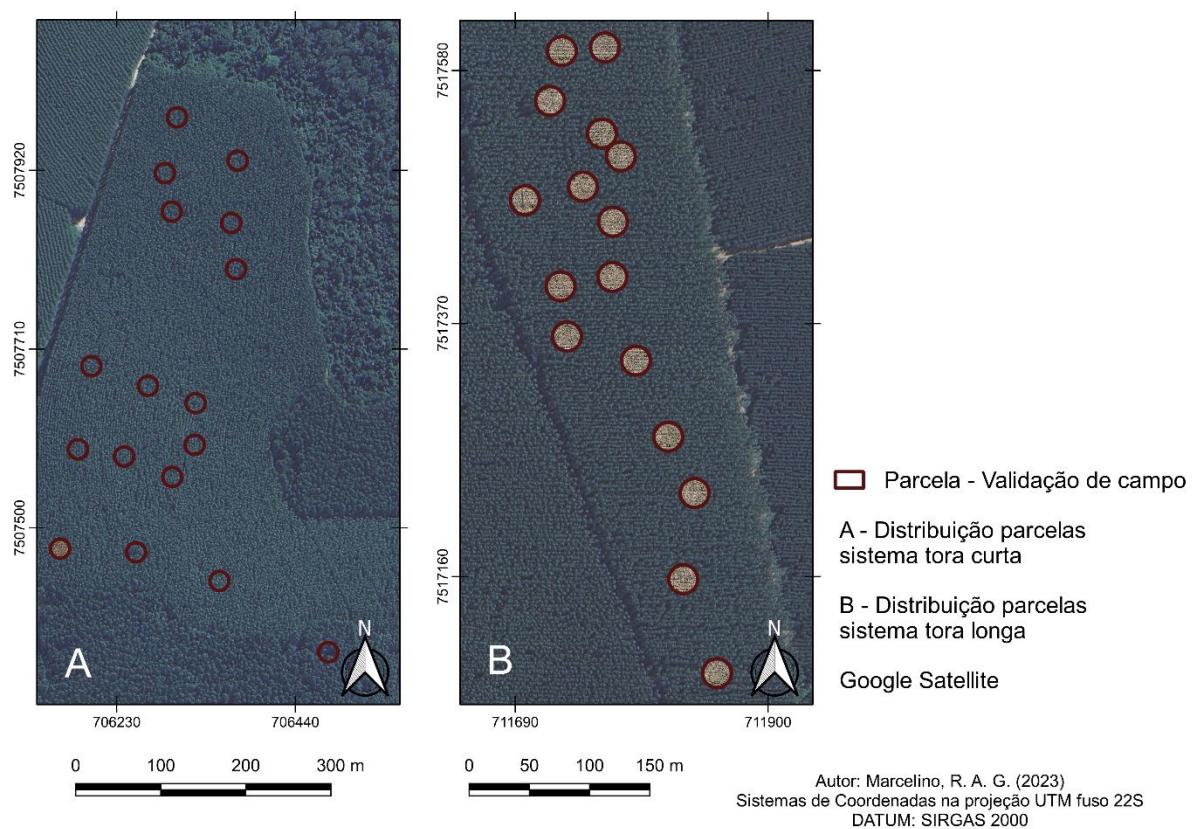


Figura 05: Distribuição amostral aleatória das parcelas para validação em campo do modelo de identificação e quantificação proposto para as áreas de estudo (A) tora curta, e (B) tora longa. Fonte: Autor (2023).

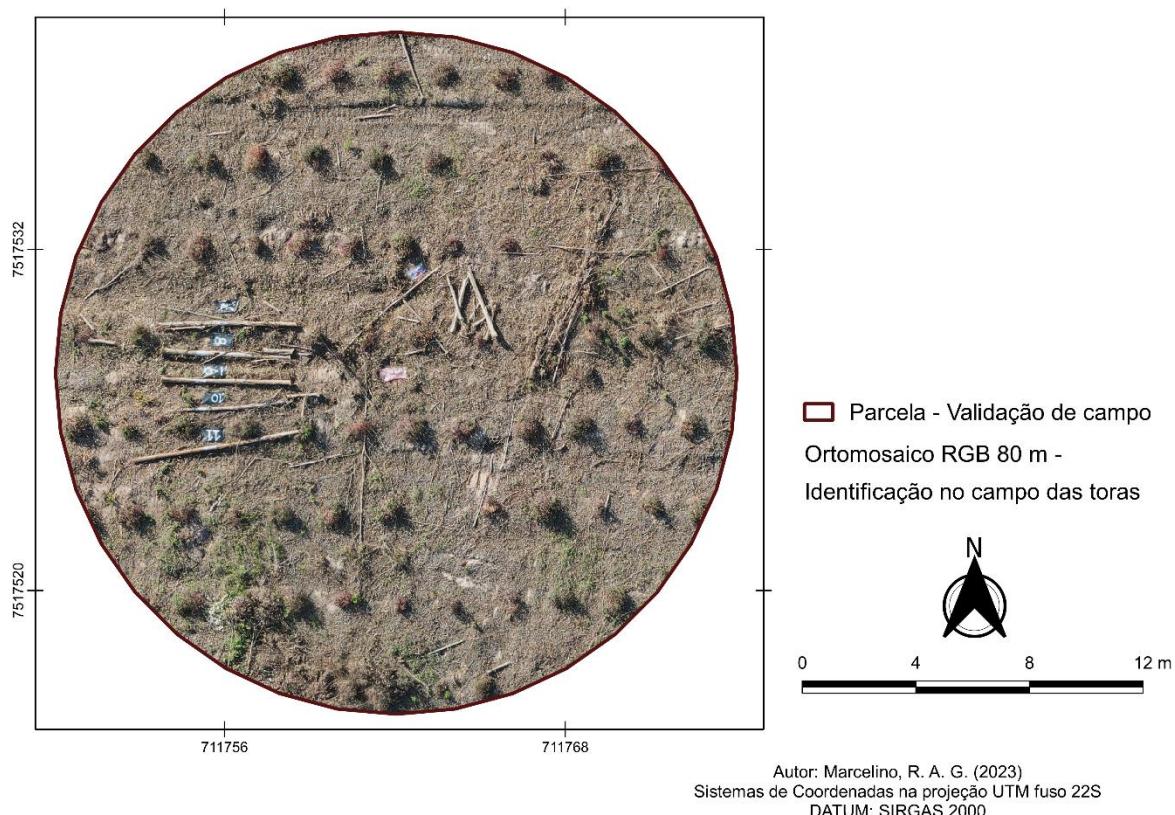


Figura 06: Parcela amostral no campo, e forma adotada para delimitar o centro da parcela e identificação das toras. Fonte: Autor, (2023).

Durante as inspeções realizadas nas parcelas de campo, foram tomadas diversas medidas e observações cruciais para a compreensão abrangente do ambiente de estudo, tais como: identificar os diferentes tipos de resíduos presentes na área, o que permitiu uma melhor compreensão das práticas locais de operação de colheita e baldeio. Foi tomado também, registros fotográficos de toras soterradas, pontuado a presença de cascas, galhos, feixes de ponteiras e outros detritos orgânicos que podem obstruir a visibilidade das toras por parte dos Aeronave remotamente pilotada e o grau de sujidade na área e a exposição de solos para facilitar as discussões após aplicação da técnica de segmentação de objetos.

Essa abordagem das parcelas amostrais, permitiu a quantificação dos resíduos madeireiros ou toras por meio de cubagem. Essa quantificação do volume das toras presentes em cada parcela foi adotada o modelo de cubagem do tipo Smalian. Assim, para todas as toras acima de um metro de comprimento, foram medidos dois diâmetros (d) para cada extremidade (quatro medições no total) e comprimento da

tora (h) (Figura 07), como forma de calcular o volume mais próximo do real presente em cada parcela.

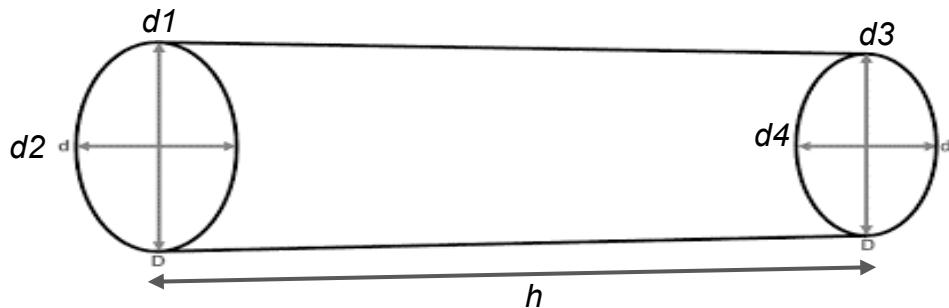


Figura 07: Esquema ilustrativo da medição nas toras para cálculo da cubagem Smalian dos resíduos nas parcelas. Fonte: Autor, (2023).

Contudo, com intuito de verificar a assertividade do modelo, foi feito uma divisão de dois critérios para inclusão das toras (> 3 metros de comprimento e ≥ 4 cm de diâmetro) denominado de resíduo comercial (desperdício da colheita), dos resíduos totais (toras > 1 m comprimento e sem delimitação de diâmetro), assim para o volume foi considerado as seguintes equações:

$$g_i = \frac{\pi * \left(\frac{d_1 + d_{i+1}}{2}\right)^2}{40000}$$

$$v_j = \frac{(g_i + g_{i+1})}{2} * h$$

$$vt = \sum v_j$$

Em que:

d_1 = diâmetro da tora em cm;

g_1 = área basal de cada extremidade da tora em m^2 ;

h = comprimento da tora em m;

v_j = volume total da tora em m^3 ;

vt = volume total da parcela em m^3 .

Sendo que os cenários avaliados detêm das seguintes estatísticas descritivas, (Tabela 02), quando se compara os dados quantitativos de volume coletados em campo.

Tabela 02: Dados descritivos referentes a cubagem dos resíduos totais e comerciais estimados para a área total dos talhões, destinada ao modelo de tora curta e tora longa.

Resíduos totais (< 4 cm diâmetro) - 17 Parcelas					
Projeto	Talhão	Média (m ³ /ha)	Máx. (m ³ /ha)	Mín. (m ³ /ha)	DesvPad. (m ³ /ha)
Tora curta	00A	21.57	48.03	10.03	9.62
Tora longa	00B	15.72	26.12	5.80	3.25
Projeto	Talhão	Vol. produção total (m ³ /ha)	% resíduo	Área (ha)	Nº toras / parcela
Tora curta	00A	345.92	6.00%	17.20	1524
Tora longa	00B	448.15	3.51%	16.39	223
Resíduos comerciais (≥ 4 cm diâmetro) - 17 Parcelas					
Projeto	Talhão	Média (m ³ /ha)	Máx. (m ³ /ha)	Mín. (m ³ /ha)	DesvPad. (m ³ /ha)
Tora curta	00A	16.66	35.51	5.99	7.98
Tora longa	00B	14.57	24.50	4.53	3.64
Projeto	Talhão	Vol. produção total (m ³ /ha)	% resíduo	Área (ha)	Nº toras / parcela
Tora curta	00A	345.92	5.00%	17.20	1214
Tora longa	00B	448.15	3.25%	16.39	183

3.4 Pré-processamento das imagens

O pré-processamento e a visualização das imagens obtidas foram realizados por meio do Sistema de Informações Geográficas QGIS (QGIS, 2023). As etapas do processamento incluíram a mosaicagem das imagens (feita pelos respectivos aplicativos da aeronave remotamente pilotada de cada sistema), seguida pela exportação e visualização da qualidade da imagem resultante para cada altura de voo. Durante esse processo, foram observados fatores como resolução espacial (tamanho do pixel), extensão e bandas espectrais (RGB) das imagens para cada área, a fim de auxiliar na etapa posterior de definição dos parâmetros do algoritmo para cada sistema, visto que foram áreas e resíduos madeireiros distintos.

Ao levar em conta a capacidade de processamento computacional, torna-se economicamente vantajoso subdividir os dados das imagens em áreas menores, a fim de prevenir erros durante o processamento e redução de tempo no processamento. Para garantia da eficiência no processamento pelo algoritmo, foi feito um procedimento de recorte nas imagens raster (para todas as alturas testadas) por meio

do código em linguagem R, no ambiente RStudio (RStudio, 2023). Nesse processo, foi carregado um arquivo shapefile no formato de polígonos para executar o recorte.

Script 1 (Para recorte nas imagens de todas as alturas testadas):

```
#Recortar arquivo raster
# Instale e carregue as bibliotecas necessárias
install.packages(c("raster", "sf", "rgdal"))
library(raster)
library(sf)
library(rgdal)
# Carregar camada raster
raster_original <- raster("C:/Users/Map.tif")
# Carregue o arquivo shapefile contendo os polígonos de recorte
shapefile <- st_read("C:/Users/SHP.shp")
shapefile <- st_transform(shapefile, crs = crs(raster_original))
# Recortar o raster para cada polígono e salvar em arquivos separados
for (i in seq_len(nrow(shapefile))) {
  poly <- shapefile[i, ]
  raster_recortado <- mask(raster_original, poly)
  # Salvar o raster recortado em um novo arquivo
  output_path <- paste0("C:/Users/Ortho_recort_", i, ".tif")
  writeRaster(raster_recortado, output_path, format = "GTiff", overwrite = TRUE)
}
```

3.5 Processamento das imagens

3.5.1 Etapas do processamento das imagens

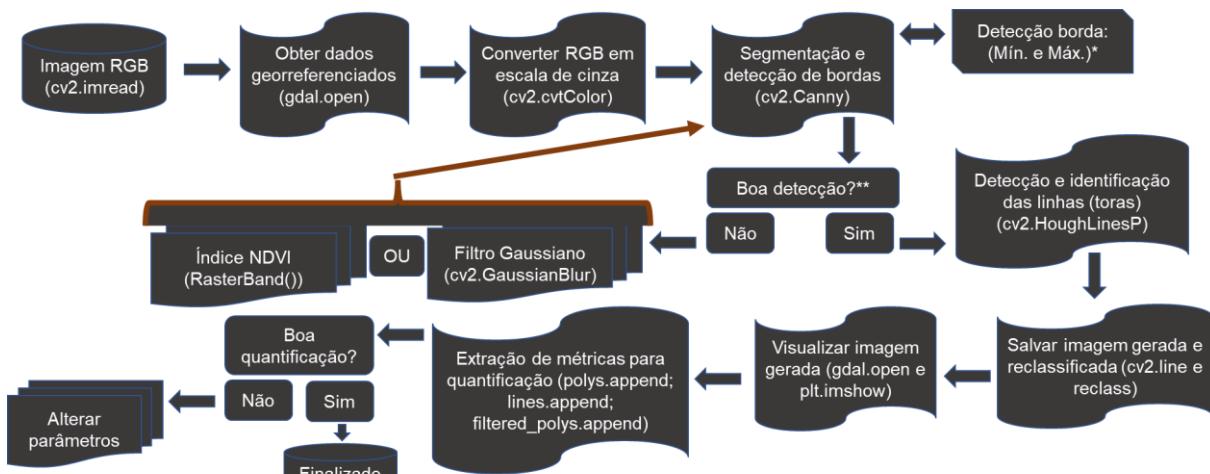
Para implementar as técnicas de segmentação e detecção de objetos e bordas é essencial criar segmentos ou regiões, considerada a etapa mais crítica desta classificação orientada ao objeto. Esses processos baseiam-se nas descontinuidades e na similaridade, tendo como referência a composição da imagem capturada por Aeronave remotamente pilotada. Nesse contexto, foram selecionadas previamente configurações na biblioteca OpenCV para todos os sistemas avaliados, que incluem a utilização de técnicas como escala de cinza (Gray – 1°), filtros de suavização (Blur e Gamma – 2°) e índices de vegetação (NDVI – 3°), seguindo essa ordem de prioridade,

respectivamente, devido a organização estrutural do algoritmo testado, ao partir do filtro mais simples ao mais complexo na imagem.

Além disso, foram definidos valores para as funções Canny e HoughLinesP, necessários para detecção de bordas, segmentação de objetos e identificação de toras na imagem RGB obtida por meio de Aeronave remotamente pilotada para cada cenário. Esses procedimentos são ilustrados no fluxo de processamento mostrado na Figura 05.

Para o desenvolvimento do modelo por meio da técnica de segmentação e detecção de objetos, foram definidas as propriedades elementares, os parâmetros de cada sistema, com o objetivo de evidenciar a distinção dos constituintes na imagem, para garantia de confiabilidade para a classificação ou identificação. Os atributos considerados nessa metodologia foram: índices e bandas espectrais que compreende diferentes composições de bandas espectrais, notadamente aquelas pertencentes ao RGB, textura que abrange a intensidade espacial dos pixels, bem como as propriedades dos níveis de cinza e os efeitos resultantes da aplicação de filtros de suavização e por fim de geometria os quais inclui a forma, área, perímetro, diâmetro, comprimento e homogeneidade dos objetos em questão.

Para implementação dessa metodologia, um fluxograma foi delineado, (Figura 08), o qual detalha as etapas do script para cada fase e parâmetro da biblioteca utilizada, bem como a sequência de ações a serem realizadas no ambiente Python.



*Etapas que permite adaptação dos parâmetros para cada cenário e finalidade a ser testado.

**Etapas da avaliação visual da detecção, somada a avaliação prévia estatística pelo código do algoritmo.

Figura 08: Etapas e funções do algoritmo OpenCV utilizadas no processamento das imagens para obtenção da identificação e quantificação dos resíduos florestais pós-colheita. Fonte: Autor, (2023).

3.6 Script do modelo de identificação e quantificação (Rotina via Python)

A descrição detalhada do código via Python, para identificação e quantificação dos resíduos pós-colheita florestal, está no Apêndice A desse documento, contendo as bibliotecas e funções totais para possibilitar a detecção de toras nas imagens dos Aeronave remotamente pilotada. Cada cenário foi avaliado em diferentes valores mínimos e máximos dos parâmetros (Tabela 03), para detecção de bordas e segmentação de objetos, a fim de auxiliar na comparação e escolha do melhor valor, pois há variação dos tipos de resíduos no solo, bem como das características do talhão no momento do voo para cada empresa.

Tabela 03: Valores testados no algoritmo com intuito de identificar os melhores parâmetros para cada cenário avaliado.

Parâmetro	Toras curtas – Área A	Toras Longas – Área B
Borda - cv2.Canny	Min (120 a 200)	Min (100 a 370)
Borda - cv2.Canny	Max (200 a 300)	Max (250 a 450)
Detecção - cv2.HoughLinesP	minLineLength = 50, 25 maxLineGap = 10, 5	minLineLength = 50, 25 maxLineGap = 10, 5
Suavização- cv2.GaussianBlur	5x5	5x5

3.7 Avaliação estatística do algoritmo

Para fins comparativos e de visualização dos resultados nos diferentes cenários avaliados, foram elaborados gráficos realizados em ambiente R e mapas no QGIS. Na validação estatística da metodologia proposta, foram adotadas duas abordagens, o AcATaMa para comparar a acurácia na classificação (1 – Resíduo e 0 – Não Resíduo) e a Validação de Campo para avaliar os desvios percentuais nos volumes de toras observados pela cubagem comparados aos estimados pelo algoritmo.

Para a avaliação de acurácia foi conduzida utilizando o plugin Accuracy Assessment of Thematic Maps ou Avaliação da Classificação de Imagens com Técnicas de Aprendizado de Máquina - AcATaMa, integrado ao software QGIS. Entre as opções de alocação de amostras, optou-se pela amostragem aleatória estratificada, com base na proporção da área. Essa abordagem emprega a fórmula de tamanho de amostra de Cochran (1977), calculando o tamanho total da amostra e

o número de pontos para cada estrato de acordo com a proporção da área de cada estrato no mapa, sendo essa proporção determinada automaticamente pelo AcATaMa. Isso implicou no número de amostras para cada classe de forma proporcional à sua representatividade no conjunto de dados original, do total de 400 amostras distribuídas nas classes para cada altura de voo, distribuídas aleatoriamente nas imagens classificadas e subsequentemente interpretadas com o auxílio de imagens obtidas pela aeronave remotamente pilotada. O valor de acurácia foi fundamental para verificar a eficácia do modelo na identificação dos resíduos (0 e 1), o que gerou uma visão precisa do desempenho do algoritmo quanto a sua assertividade na identificação.

4. RESULTADOS E DISCUSSÃO

4.1 Algoritmo de identificação e quantificação

De forma geral, foi possível estabelecer uma metodologia eficaz para a identificação e quantificação de resíduos, ao considerar distintos sistemas de colheita (toras curtas e longas) por meio de imagens capturadas por Aeronave remotamente pilotada, com o algoritmo desenvolvido, (Figura 09). Um dos benefícios proeminentes desse procedimento é a eliminação da necessidade de uma fase de treinamento. Contudo, para cada sistema de colheita, são recomendados valores específicos para os parâmetros, principalmente em razão das características espectrais e espaciais (Tabela 04). As variações nas alturas de voo e na resolução espacial, ao influenciarem a diferenciação e segmentação de objetos, assim como a detecção de bordas, revelaram disparidades significativas entre as diferentes alturas e sistemas.

Ao considerar a diferença entre alturas e sistemas, conforme refletido nas avaliações de campo e acurárias, (Tabela 04), observa-se comportamentos semelhantes para ambos os sistemas, devido aos índices de desvios volumétricos serem mais elevados em alturas de voo mais baixas (menores pixels). Quando se avalia a assertividade do algoritmo com o real em campo (cubagem), as alturas de 120 m (tora curta) e 80 m (tora longa), apresentaram as melhores avaliações de acurácia, de 0,88 e 0,85, respectivamente e variação no desvio volumétrico de até 2,5 %, aproximadamente. Isso vale quando se compara o desvio de número de toras dessas respectivas alturas, o qual para os dois sistemas apresentaram um desvio

médio de número de toras abaixo de 8%, ou seja, o número de toras que o algoritmo detectou foi em média 8% maior que a quantidade realmente tinha em campo.

Porém, ao considerar o sistema de tora curta, as imagens realizadas a 120 m, seguidas pela altitude de 90 m, obtiveram resultados próximos à validação de campo. No caso do sistema de tora longa, os resultados indicaram alturas de voo de 80 m, seguidas pelas de 60 m, contudo ao verificar as imagens de identificação pelo algoritmo apresentam resultados divergentes, isso é devido à dificuldade do algoritmo em detectar toras em imagens de voos mais baixos (menores pixels).

Ao analisar os parâmetros para a detecção e segmentação de objetos, assim como a identificação das geometrias lineares (toras), foram observados valores distintos para cada tipo de sistema, ou seja, em detrimento das diferenças de resíduos madeireiro o algoritmo também necessita de parâmetros distintos para cada sistema de colheita. Estes resultados ressaltam a existência de limites ótimos, tanto máximos quanto mínimos durante a etapa de segmentação de bordas (percebe que há uma variação dos desvios mesmo dentro da classe de altura), e isso para cada atributo que compõe a imagem de acordo com a altitude de voo testado, assim como autores atuais corroboram com essas afirmações (Zhou et al. 2020; Sriram et al. 2021; Zhou et al. 2023).

Tabela 04: Diferentes atributos e parâmetros testados no algoritmo comparados aos resultados da cubagem de campo para os dois cenários tora curta e longa.

Cenário (Sistema)	Altura de voo (m)	cv2. Canny (min. e máx)	HoughLinep (min. e max.)	Vol médio (m ³ /ha)	Vol médio cubagem (m ³ /ha)	Desvio Volumétrico	Acurácia AcATaMa	Desvio Nº de toras
Tora Curta - Área A	60	150-250	50-10	57.53	16.66	40.87%	0.48	20%
	60	150-250	25-5	30.38	16.66	13.72%	0.51	25%
	60	120-300	50-10	69.53	16.66	52.87%	0.44	19%
	60	120-300	25-5	38.75	16.66	22.09%	0.56	30%
	60*	150-300	50-10	28.93	16.66	12.27%	0.55	15%
	60*	150-300	25-5	27.75	16.66	11.09%	0.53	19%
	90	150-250	50-10	46.08	16.66	29.42%	0.42	22%
	90*	150-250	25-5	23.65	16.66	6.99%	0.62	10%
	90*	170-280	50-10	19.98	16.66	3.32%	0.67	11%
	90	170-280	25-5	9.73	16.66	-6.94%	0.55	22%
	90	130-260	50-10	57.73	16.66	41.07%	0.4	24%
	90	130-260	25-5	27.48	16.66	10.82%	0.45	22%
	120	150-200	50-10	48.00	16.66	31.34%	0.47	20%

Cenário (Sistema)	Altura de voo (m)	cv2. Canny (min. e máx)	HoughLinep (min. e max.)	Vol médio (m ³ /ha)	Vol médio cubagem (m ³ /ha)	Desvio Volumétrico	Acurácia AcATAma	Desvio Nº de toras
Tora Longa Área B	120*	150-200	25-5	18.80	16.66	2.14%	0.88	8%
	120*	170-250	50-10	16.43	16.66	-0.23%	0.85	6%
	120	170-250	25-5	14.98	16.66	-1.69%	0.59	13%
	120	200-260	50-10	19.48	16.66	2.82%	0.56	19%
	120	200-260	25-5	11.48	16.66	-5.19%	0.53	18%
	40	200-350	50-10	60.25	14.57	45.68%	0.31	24%
	40	200-350	25-5	31.50	14.57	16.93%	0.41	23%
	40	250-400	50-10	48.75	14.57	34.18%	0.33	22%
	40	250-400	25-5	38.25	14.57	23.68%	0.36	26%
	40*	370-450	50-10	25.50	14.57	10.93%	0.49	18%
Tora Curta Área A	40*	370-450	25-5	11.95	14.57	-2.62%	0.42	19%
	60	150-350	50-10	46.70	14.57	32.13%	0.44	20%
	60*	150-350	25-5	17.03	14.57	2.46%	0.58	17%
	60	175-350	50-10	43.03	14.57	28.46%	0.49	20%
	60*	175-350	25-5	13.98	14.57	-0.59%	0.59	16%
	60	200-400	50-10	58.03	14.57	43.46%	0.33	20%
	60	200-400	25-5	47.25	14.57	32.68%	0.39	18%
	80	100-250	50-10	26.53	14.57	11.96%	0.55	18%
	80*	100-250	25-5	13.98	14.57	-0.59%	0.85	8%
	80	150-300	50-10	45.83	14.57	31.26%	0.54	15%
	80*	150-300	25-5	16.25	14.57	1.68%	0.83	7%
	80	200-350	50-10	47.63	14.57	33.06%	0.45	15%
	80	200-350	25-5	25.26	14.57	10.69%	0.51	14%

* Parâmetros que apresentaram melhores resultados quanto ao desvio volumétrico e número de toras médio das parcelas

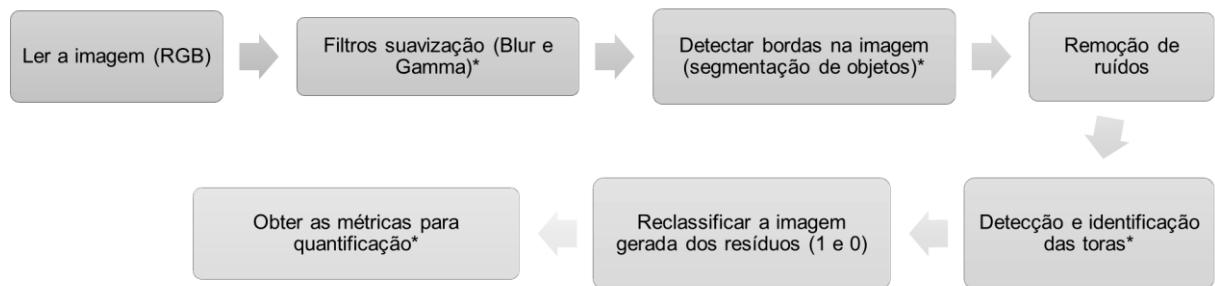


Figura 09: Etapas sequenciais utilizadas para o processamento das imagens via algoritmo para os dois sistemas, após avaliação dos resultados. Fonte: Autor, (2023).

A aplicação eficaz das ferramentas e funções do OpenCV neste estudo exige uma compreensão profunda do funcionamento dos parâmetros. Essa compreensão não se limita apenas a este estudo específico, mas representa uma necessidade

fundamental para qualquer pesquisa que tenha como objetivo o reconhecimento de objetos em imagens ao utilizar esta biblioteca. A familiaridade com as configurações é essencial para otimizar e ajustar os resultados, o que garante precisão e confiança na detecção e análise de objetos na imagem.

Esses resultados ganham destaque quando se comparam as imagens originais (RGB) em várias alturas de voo com as segmentadas e bordas detectadas pelo algoritmo, (Figura 10). Após testes nessa metodologia, ficou nítido que, com uma alta resolução espacial das imagens (obtidas em altitudes menores, como 60 m para o primeiro cenário e 40 m para o segundo), o processo de segmentação e detecção das bordas dos objetos na imagem se torna mais complexo, o que dificulta a identificação das toras, elevando os desvios em mais de 18% em média. Uma etapa crucial para o sucesso da metodologia de identificação é a detecção e segmentação das bordas, uma vez que elimina o alto nível de ruído facilitando a etapa posterior de identificação das toras, (Figura 10) (Ribeiro et al. 2020; Li et al. 2022; Xia et al. 2022).

Em processamento de imagens de alta resolução espacial, o termo "ruído" refere-se a variações ou interferências indesejadas nas características da imagem que não representam informações relevantes para a análise pretendida. Podem ser causadas por alguns fatores e impactar negativamente a qualidade e precisão das análises realizadas sobre a imagem, tais como: ruído de sensor, atmosférico, iluminação, compressão ou eletrônico. É importante ressaltar que a relação entre altura de voo e ruído não é uma regra fixa, e diferentes situações podem resultar em diferentes efeitos. Em que nessa metodologia teve-se de lidar com ruídos na segmentação dos objetos na imagem em detrimento dos atributos de coleta e sistemas de colheita adotados.

Quando se avalia os desvios estatísticos de volume e número de toras para o sistema de toras curtas, associado a imagem capturada a 120 metros nota-se que o algoritmo apresentou melhor assertividade para segmentar os objetos e suprimir ruídos, (Figura 11), o que vem a facilitar o processo de identificação individual das toras (geometrias lineares), ao contrário do que foi observado na imagem a 60 metros, para mesmo sistema. No caso do sistema de toras longas, um padrão semelhante também foi identificado em relação às alturas de voo (Figura 11), sendo a imagem capturada a 80 metros o algoritmo apresentou melhores resultados comparado a de 40 metros, que quase não foi possível diferenciar os segmentos dos objetos na imagem, mesmo ao considerar os filtros e índices adicionais dessa metodologia.

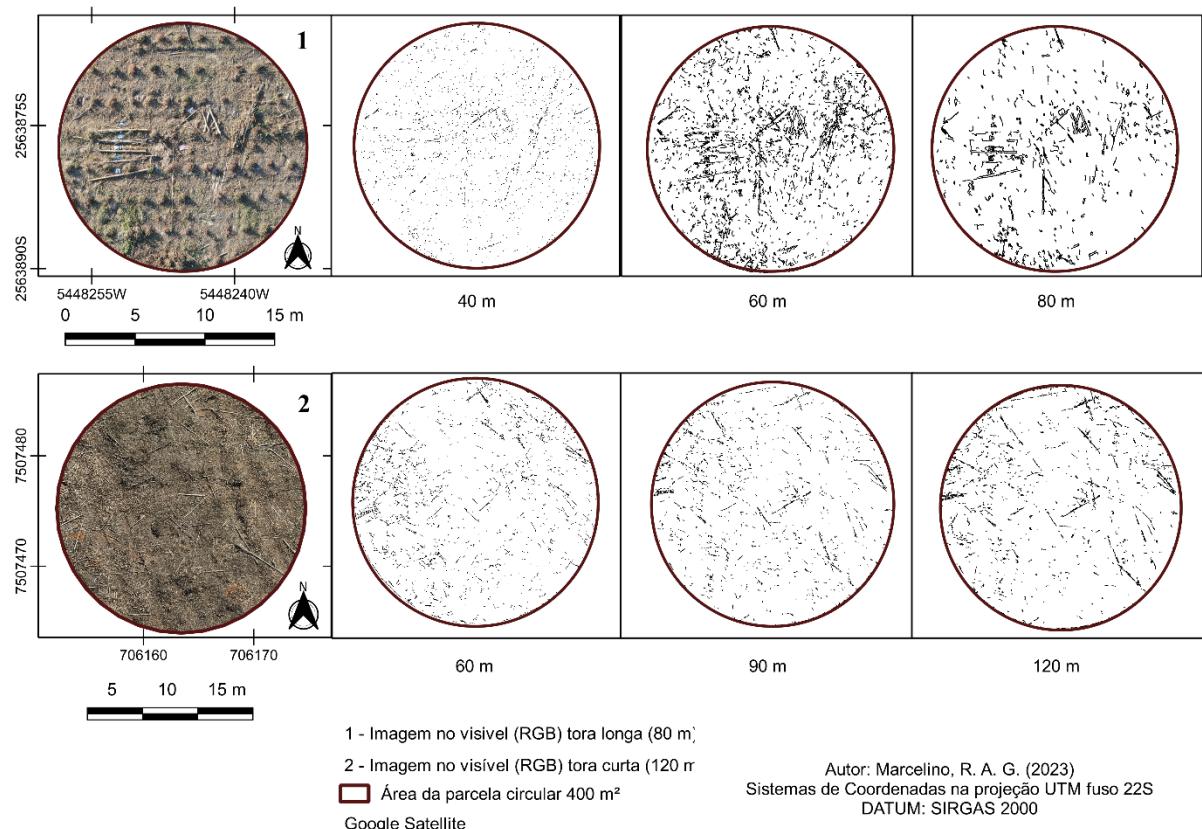


Figura 10: Detecção de bordas e segmentação de objetos pelo algoritmo nas diferentes alturas avaliadas: 1) sistema de toras longas 2) sistema de toras curtas.
 Fonte: Autor, (2023).

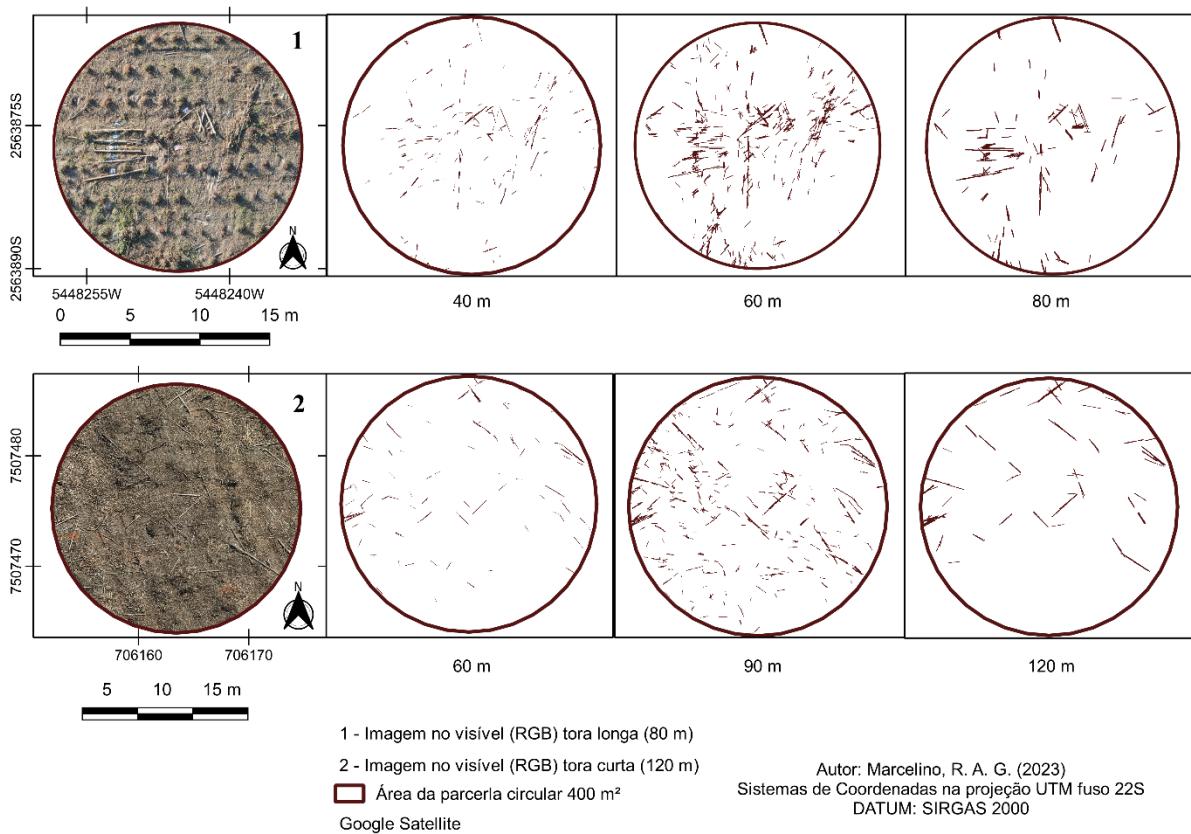


Figura 11: Identificação das toras pelo algoritmo nas diferentes alturas avaliadas: 1) sistema de toras longas 2) sistema de toras curtas. Fonte: Autor, (2023).

Essa análise entre alturas distintas impacta de maneira direta na eficiência operacional da aquisição de imagens por aeronave remotamente pilotada pelas equipes de campo nas empresas, visto que quanto maior a altura de voo maior o rendimento em hectares avaliados. Do ponto de vista da gestão de qualidade, essa abordagem é crucial, pois amplia o escopo de áreas a serem avaliadas, logo espera-se resultados e processamentos mais rápidos.

A resolução espacial exerce impacto significativo na densidade de informações por centímetro quadrado na imagem em relação a quantidade de informação dos alvos. Assim, uma resolução espacial maior, descrita por pixels menores, pode complicar o processo de análise, uma vez que a interpretação de dados detalhados em alta resolução exige capacidades de processamento mais complexas, por vezes tornando-se inviável, além disso, acabou por dificultar a identificação de resíduos madeireiros pelo algoritmo, principalmente quando se observa os desvios das resoluções menores comparadas as maiores. Além disso, estudos (Ding, et al. 2019; Alomari, et al. 2020; Pádua, et al. 2017; Shleymovich et al. 2016), destacam a

relevância de considerar a complexidade inerente na separação de objetos durante a identificação de toras, visto que imagens de Aeronave remotamente pilotada frequentemente apresentam diversos níveis de ruído e interferência, como: local do voo, hora do voo, luminosidade, chuva, presença de cascas e folhas o que dificultam a visualização da tora em campo e na imagem.

Em relação aos filtros de suavização, são sensíveis ao nível de informação e detalhamento presentes no pixel (Zhang et al. 2018a), e nessa pesquisa foram cruciais para o sucesso do processamento do algoritmo na identificação das toras na imagem. Embora o filtro Blur tenha sido amplamente empregado para suavizar imagens e diminuir o ruído, seu impacto na segmentação de objetos em imagens de Aeronave remotamente pilotada pode ser variável. Conforme destacado em um estudo contínuo conduzido por Zhang et al. (2018a), esse filtro pode auxiliar na redução de pequenas variações na intensidade dos pixels, resultando em bordas menos nítidas e menos detalhes nas regiões de transição. Essa condição pode resultar em uma segmentação menos precisa, especialmente em áreas caracterizadas por alta complexidade de texturas e bordas, entretanto, isso varia com a característica da imagem coletada e objetivos da pesquisa, tais como, a resolução adotada, o objeto a ser segmentado, a cobertura vegetal do local.

O filtro gama é geralmente aplicado para controlar o contraste da imagem. Conforme indicado na pesquisa de Smith et al. (2016), a configuração inadequada dos parâmetros do filtro gama pode resultar em distorções indesejadas na imagem, o que causa perda de informações sutis, principalmente em áreas de sombras e regiões reais, e isso pode ter um impacto negativo na detecção de bordas e na segmentação de objetos, ao comprometer a precisão geral do processo.

Portanto, ao se aplicar esses filtros, é crucial ajustar suas configurações de forma a equilibrar a suavização do ruído sem comprometer a nitidez das bordas e a fidelidade das características relevantes para a segmentação de objetos. Esse ajuste deve levar em consideração intimamente a altura de voo escolhida e os resultados prévios na segmentação. Além disso, considerar o contexto específico da cena e as características das imagens de Aeronave remotamente pilotada é fundamental para garantir resultados precisos e confiáveis na detecção e segmentação de objetos.

4.2 Distribuição de resíduos

Compreender a diversidade nas dimensões dos resíduos e ajustar o algoritmo e parâmetros de acordo é crucial para uma identificação precisa de toras, principalmente ao considerar diferentes sistemas de colheita florestal. Uma análise comparativa da distribuição de resíduos para os dois sistemas de colheita revela comportamentos distintos no que diz respeito à prevalência no campo de toras com diâmetros menores.

No sistema de toras curtas, aproximadamente, 84% do volume total de toras é composto por toras com comprimentos maiores que 3 metros. Em relação ao diâmetro, cerca de 93% dos resíduos encontrados nas parcelas possuem diâmetro superior a 4 cm, indicando a presença significativa de resíduos passíveis de reaproveitamento ou reciclagem que foram deixados na área pós-operações de colheita, (Figura 12). Já para o sistema de toras longas, aproximadamente 68% do volume total é composto por toras com comprimentos superiores a 3 metros, já relacionado ao diâmetro das toras quase 100 % apresentam valores superiores a 4 cm (Figura 13).

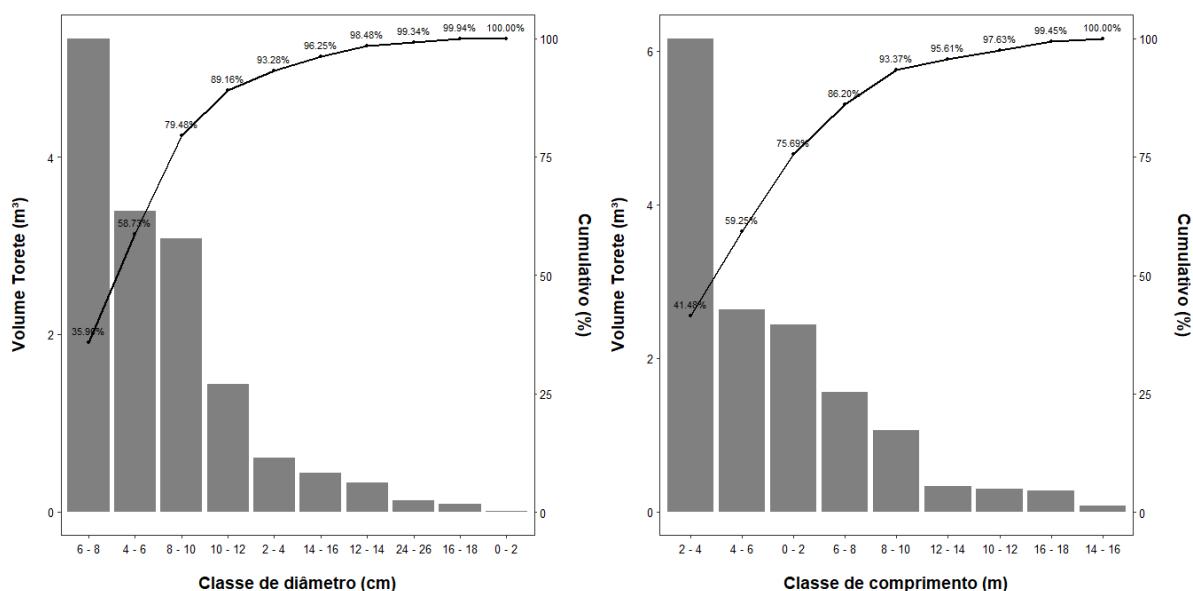


Figura 12: Distribuição do volume dos resíduos por classe de comprimento e de diâmetro para o sistema de toras curtas. Fonte: Autor, (2023).

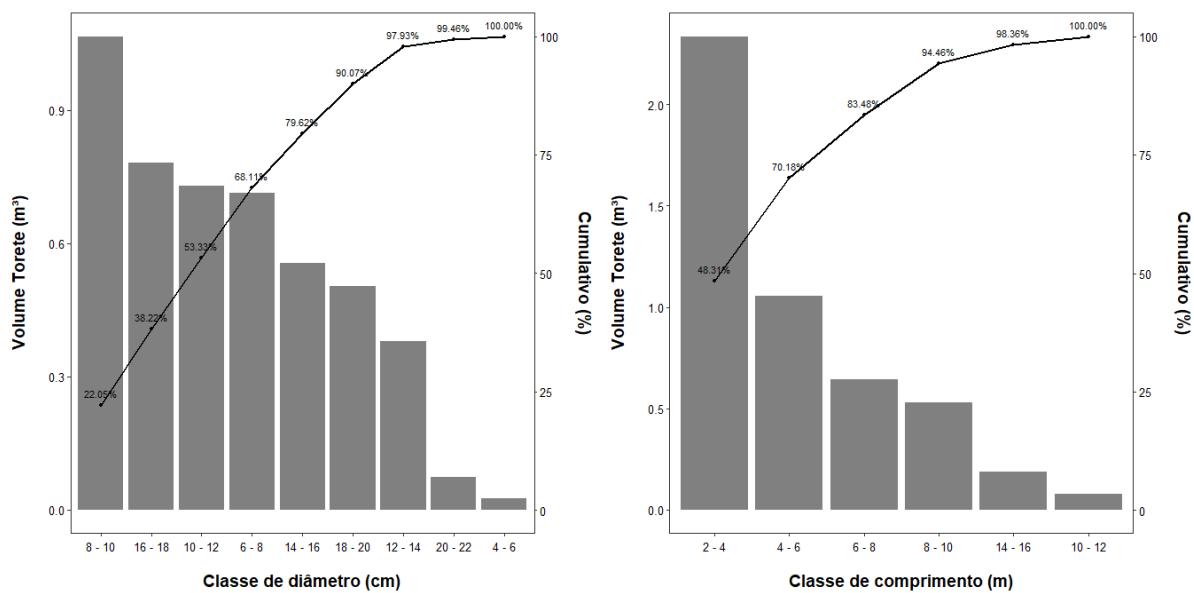


Figura 13: Distribuição do volume dos resíduos por classe de comprimento e de diâmetro para o sistema de toras longas. Fonte: Autor, (2023).

O sistema de colheita de toras curtas se destaca pela produção de toras de menor comprimento, resultando em uma quantidade significativa de resíduos, como cascas, galhos e ponteiras, dispersos pelo solo. Essa característica distintiva desse sistema é a presença de resíduos fragmentados e distribuídos no solo. Em contraste, o sistema de toras longas concentra-se no corte de árvores de maior comprimento, resultando em menos resíduos dispersos no solo e uma maior centralização dos feixes de outros resíduos, incluindo cascas. Essa centralização é facilitada pela presença das cascas nas toras durante a colheita, levando a uma disposição mais ordenada dos resíduos no talhão. Essas discrepâncias na geração e distribuição de resíduos entre os sistemas de toras curtas e longas desempenham um papel crucial na compreensão das variações observadas nas práticas de colheita florestal (Pena-Vergara et al., 2022).

Ao avaliar toda essa distribuição dos resíduos na assertividade do algoritmo na identificação e quantificação das toras na imagem, gera alguns questionamentos chave para maior compreensão da metodologia e seus parâmetros testados nessa pesquisa. São elas: Como a dimensão dos resíduos afetam a predição no algoritmo de identificação de toras? A cobertura do solo nos dois sistemas de colheita é diferente, como isso afeta o acerto do algoritmo ao identificar as toras na imagem?

Sabe-se que o comprimento e as dimensões dos resíduos têm um impacto significativo na identificação de toras, logo, o algoritmo, ao processar imagens de uma aeronave remotamente pilotada para identificar toras, leva em consideração características como forma, tamanho e padrões dos objetos na imagem e sua distribuição. Fatores como: Resíduos mais longos podem ter bordas mais distintas, facilitando a detecção, enquanto resíduos menores podem ser mais difíceis de identificar, assim, se a resolução espacial for muito baixa, os resíduos menores podem ser perdidos na imagem ou confundidos com o fundo pelo algoritmo.

Logo, resíduos de diferentes dimensões podem introduzir níveis variados de ruído na imagem após identificação pelo algoritmo. O processamento de resíduos maiores pode exigir mais recursos computacionais e ou aplicação de filtros de suavização como vimos nessa pesquisa. Dependendo da capacidade do sistema computacional pode afetar o desempenho do algoritmo. O ambiente de colheita, toras semi soterradas, a densidade dos resíduos, podem influenciar na forma como as dimensões dos alvos são detectadas pelos algoritmos na imagem, bem como impactar nos desvios volumétricos aparentes, como visto na pesquisa.

4.3 Processamento, novos passos e melhorias

Os ajustes dos parâmetros de detecção de bordas desempenham um papel crítico na precisão e confiabilidade da identificação de objetos (Wang et al. 2020; Ribeiro et al. 2020; Xia et al. 2022), incluindo as toras. Os intervalos de variação nos valores mínimos e máximos das funções de segmentação, detecção e identificação de resíduos desempenham um papel crítico na eficácia do algoritmo para a detecção precisa de contornos e bordas em imagens. Em termos mais específicos, esses limites são essenciais para discernir entre o ruído de fundo e os objetos de interesse na cena. Valores excessivamente baixos podem resultar em uma detecção intensificada de bordas e detalhes insignificantes, o que gera um aumento no ruído e na detecção de características indesejadas. Por outro lado, valores excessivamente altos podem acarretar a perda de informações cruciais, ocasionando a não detecção de bordas e objetos relevantes, como destacado nos parâmetros avaliados nesta pesquisa.

Além disso, é evidente, na segmentação dos objetos para os dois cenários investigados (toras curtas e longas), (Figuras 14 e 15), que a intensidade das bandas RGB desempenha um papel distintivo, ou seja, quais dados espectrais foram mais influentes no algoritmo. Fica claro que, à medida que o valor da intensidade média

aumenta, a influência da respectiva banda na detecção de bordas é ampliada, fenômeno mais notório nos valores de intensidade associados às toras curtas em comparação com as toras longas.

Entretanto, ao analisar cada sistema, constata-se que, no caso das toras curtas, não há variação significativa entre as bandas considerando as altitudes de voo testadas. Por outro lado, ao avaliar as toras longas, observam-se padrões distintos entre as altitudes de voo, sendo notável, especialmente a 80 metros, a proeminência da intensidade na banda vermelha em relação às demais. Essa análise destaca a proximidade dos valores associados aos parâmetros da função de segmentação de bordas ao comparar diferentes sistemas em diversas altitudes de voo, ao considerar suas respectivas características distintas de resíduos.

As imagens RGB podem apresentar comportamentos distintos durante o processamento devido à variação na intensidade das bandas espectrais, o que influencia a capacidade de distinguir e identificar, de maneira específica, as toras nas imagens de Aeronave remotamente pilotada. É relevante destacar que, em virtude das disparidades nos sistemas e nas características dos resíduos de madeira, como a presença de cascas e a distribuição de outros detritos no solo, ocorrem impactos significativos na reflectância e nos índices espectrais em ambos os casos. Estudos, como os de Hu et al. (2017), Shah et al. (2019) e Guo et al. (2020), têm enfatizado a importância de considerar a intensidade das bandas espectrais na realização da segmentação de objetos em imagens RGB, ao explorar diferentes características espectrais para aprimorar a precisão desse processo.

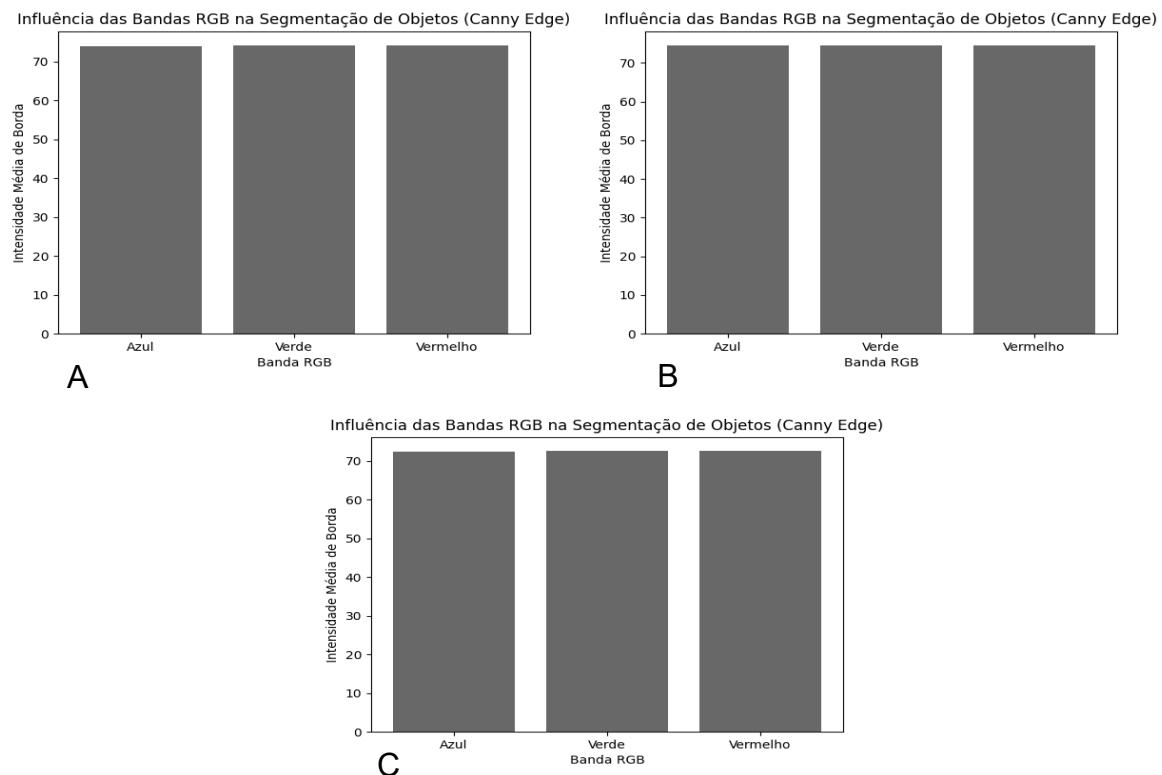


Figura 14: Intensidade das bandas espectrais sob a influência da função *Canny* do sistema de toras curtas, nos voos (A – 60, B – 90 e C – 120 m). Fonte: Autor, (2023).

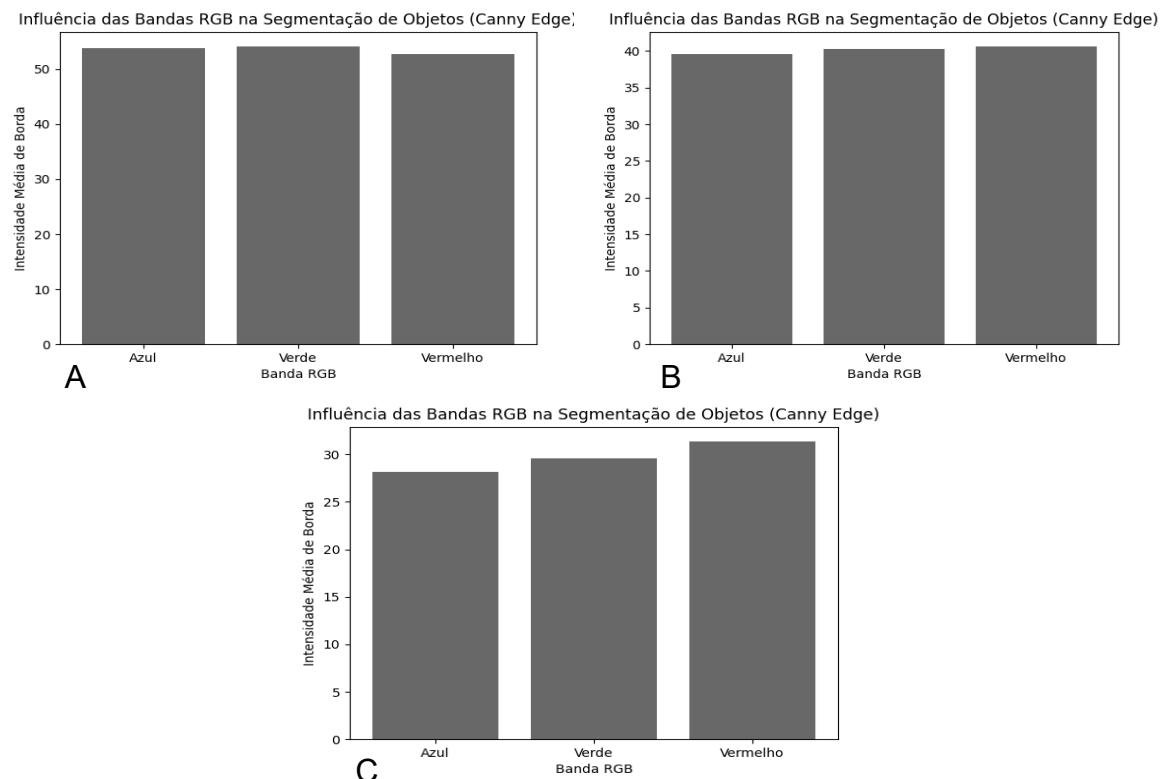


Figura 15: Intensidade das bandas espectrais sob a influência da função *Canny* do sistema de toras longas, nos voos (A – 40, B – 60 e C – 80 m). Fonte: Autor, (2023).

De forma geral, a presença da casca de uma árvore possui características ópticas diferentes em comparação com a madeira sem casca. A presença de cascas pode introduzir variações significativas na refletância da luz em diferentes comprimentos de onda (Toscano et al. 2017). Em imagens espectrais, como aquelas obtidas por sensores em Aeronave remotamente pilotada, as características espectrais da casca podem levar a diferenças nas assinaturas espectrais entre madeira com casca e madeira sem casca (Dinulică et al. 2019). Essas diferenças nas assinaturas espectrais podem ser exploradas para identificar e distinguir áreas com madeira com casca das áreas com madeira sem casca em imagens de Aeronave remotamente pilotada. Isso é particularmente relevante em aplicações como a detecção de toras ou resíduos de madeira em operações florestais, o que é um dos indicativos de diferença da resposta do algoritmo ao ser aplicado no sistema de tora curta e tora longa.

A interação entre as propriedades das imagens e as características dos resíduos florestais tem sido objeto de estudo, com foco no desenvolvimento de técnicas de processamento personalizadas para a detecção precisa e eficiente de toras em imagens provenientes de Aeronave remotamente pilotada. Estudos anteriores, como os de Zhang et al. (2018a), Li & Wang (2019) e Sun et al. (2019), investigaram diversas abordagens, estabeleceram correlações entre as características dos resíduos e os sinais espectrais, além de desenvolverem algoritmos especializados para lidar com a complexidade das imagens de florestas e as variações na composição dos resíduos de madeira, semelhante ao enfoque proposto neste estudo. Entretanto, é importante ressaltar que esse campo ainda é pouco explorado nas pesquisas brasileiras no que tange resíduos florestais.

A singularidade desta abordagem metodológica proposta reside em sua capacidade de enfrentar desafios altamente complexos por meio de abordagens diretas e eficientes. Principalmente ao comparar com modelos de Deep Learning que necessitam de uma amostragem extremamente complexa e com um número exorbitantemente grande de amostras para garantia de representatividade, o que nesse algoritmo é totalmente dispensável, uma vez que não tem essa etapa de

treinamento. Além disso, esse algoritmo é um método automatizado com todas as etapas codificadas e realizadas em um único ambiente de programação, Python.

Adicionalmente, a metodologia concentra-se no monitoramento e controle do desempenho das operações de colheita florestal. No entanto, uma das estratégias mais sólidas e eficazes para minimizar a presença de resíduos é intervir em sua origem diretamente durante as atividades operacionais de colheita florestal, logo com o algoritmo proposto consegue-se avaliar com precisão o volume de resíduos madeireiros deixados no talhão com antecedência para mensurar perdas, gerar ações de qualidade operacional e indicadores de tratativas nas áreas críticas.

Na literatura, vários estudos exploraram métodos alternativos para a segmentação de imagens no diagnóstico ambiental, por meio de Aeronave remotamente pilotada, especialmente em contextos internacionais, destacam-se contribuições como as de Kizha & Han (2015), Ma et al. (2017), Davis (2017), Choudhry & O'Kelly (2018), Windrim et al. (2019), Lopes Queiroz et al. (2020), Shokirov et al. (2021) e Dainelli et al. (2021; 2021a), além de Miller et al. (2022).

Entretanto, o desenvolvimento e aplicação dessa técnica em interface com as áreas da colheita florestal e mensuração de resíduos madeireiros por meio de imagens ainda carece de ampla difusão no setor, principalmente devido à sua facilidade de integração com os processos de gestão de qualidade. Nem todas as empresas possuem atualmente um portfólio consolidado para a adoção dessas práticas, revelando um espaço promissor para o desenvolvimento de novas tecnologias no cenário nacional.

O monitoramento contínuo dos resíduos madeireiros viabiliza a estratificação de áreas críticas, o que possibilita a identificação de variações entre os materiais genéticos propensos à geração de resíduos, como árvores suscetíveis a quebras durante o corte. Adicionalmente, esse processo estabelece um histórico de monitoramento, proporcionando destaques sobre os módulos de colheita mais sensíveis, o que aprimora assim a gestão de qualidade nos procedimentos e na tomada de decisões.

Pesquisas recentes conduzidas por Oliveira & Santos (2020), Silva & Costa (2019) e Pereira & Carvalho (2021) revelam que empresas florestais que negligenciam o monitoramento dos resíduos pós-colheita enfrentaram perdas significativas na gestão da qualidade e nas operações florestais. Essas perdas abrangem ineficiências na alocação de recursos, desafios na previsão de demanda, desperdício de custos

materiais, impactos negativos na imagem corporativa devido a práticas não sustentáveis.

Em contrapartida, empresas que implementam um monitoramento eficaz dos resíduos pós-colheita experimentam benefícios substanciais. Estes incluem a uso viável de recursos, a redução do desperdício de madeira, o controle ambiental, a conformidade com normas regulatórias, melhorias contínuas na eficiência operacional, bem como a valorização da marca por meio de práticas responsáveis e sustentáveis. Além disso, o monitoramento apropriado possibilita uma compreensão mais abrangente dos processos internos e externos da instituição.

Assim, o avanço no desenvolvimento de medidas que viabilizam a avaliação contínua e eficaz de dados espaciais, por meio de técnicas de modelagem, tem impulsionado estudos aplicáveis e precisos no setor florestal. As técnicas de segmentação de objetos, aliadas a imagens de alta resolução espacial provenientes de Aeronave remotamente pilotada, e a modelagem baseada em inteligência artificial, têm se destacado pelo processamento preciso e detecção de objetos que refletem fielmente a realidade do talhão. Neste estudo, uma nova abordagem de Análise de Objetos Baseada em Imagem (OBIA) foi apresentada no ambiente Python, abrindo caminho para aprimoramentos futuros, e os resultados obtidos foram promissores e bem-sucedidos.

5. CONCLUSÕES

A abordagem metodológica empregada com esse algoritmo desenvolvido revelou eficácia e precisão na identificação e quantificação de resíduos em ambientes florestais, utilizando imagens obtidas por aeronave remotamente pilotada e ao considerar diferentes sistemas de colheita, toras curtas e longas, como proposto. As altitudes ideais de voo foram determinadas como 120 metros para toras curtas e 80 metros para toras longas, levando em conta o índice de suavização aplicado na detecção de bordas, resultando em desvio volumétrico inferior a 2,5 % em ambos os cenários, e acurácia, de 0,88 e 0,85, respectivamente. A flexibilidade, reproduzibilidade e aplicabilidade demonstradas nessa metodologia enfatizam sua utilidade no monitoramento pós-colheita e na implementação de estratégias para aprimorar a gestão de qualidade nas subsequentes operações de colheita e silvicultura. Para

pesquisas futuras, recomenda-se a exploração de imagens infravermelhas a fim de avaliar seu impacto nos atributos das imagens durante a detecção e segmentação de bordas, especialmente em áreas com a presença de toras com cascas.

REFERÊNCIAS

ABBURU, S., & GOLLA, S. B. (2015). Satellite image classification methods and techniques: A review. *International journal of computer applications*, 119(8).

ADDINK, E. A., VAN COILLIE, F. M. B., & DE JONG, S. M. (2012). Special Issue on Geographic Object-based Image Analysis: GEOBIA. *International Journal of Applied Earth Observation and Geoinformation*, 15, 1-104.

ALOMARI, M., AL-MAJEED, S., & REMPEL, R. A. (2020). Challenges and Opportunities of Aeronave remotamente pilotada-Based Remote Sensing for Phenotyping. *Aeronave remotamente pilotada*.

ANAC. (2022). Agência Nacional de Aviação Civil - Aeronave remotamente pilotada. Disponível em: <[https://www.gov.br/anac/pt-br/assuntos/Aeronave remotamente pilotada](https://www.gov.br/anac/pt-br/assuntos/Aeronave%20remotamente%20pilotada)> Acesso em: outubro de 2022.

ANATEL. (2022). Agência Nacional de Telecomunicações - Aeronave remotamente pilotada devem ser homologados para evitar interferências. Disponível em: <<https://www.gov.br/anatel/pt-br/legislacao>> Acesso em: outubro de 2022.

ARVOR, D., DURIEUX, L., ANDRÉS, S., & LAPORTE, M. A. (2013). Advances in Geographic Object-Based Image Analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 125-137.

AUGUSTYNCZIK, A. L. D., ARCE, J. E., YOUSEFPOUR, R., & DA SILVA, A. C. L. (2016). Promoting harvesting stands connectivity and its economic implications in Brazilian forest plantations applying integer linear programming and simulated annealing. *Forest Policy and Economics*, 73, 120-129.

BAENA, S., BOYD, D. S., & MOAT, J. (2018). UAVs in pursuit of plant conservation-Real world experiences. *Ecological informatics*, 47, 2-9.

BARGOS, D. C., & MATIAS, L. F. (2018). O papel das geotecnologias no desenvolvimento do pensamento espacial. *Anekumene*, (15), 48-59.

BARRETO, P., AMARAL, P., VIDAL, E., & UHL, C. (1998). Costs and benefits of forest management for timber production in eastern Amazonia. *Forest ecology and management*, 108(1-2), 9-26.

BHOJANAPALLI, S., CHAKRABARTI, A., GLASNER, D., LI, D., UNTERTHINER, T., & VEIT, A. (2021). Understanding robustness of transformers for image classification. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 10231-10241).

BLASCHKE, T. (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16.

BLASCHKE, T., & STROBL, J. (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Zeitschrift für Geoinformationssysteme*, 12-17.

BLASCHKE, T., HAY, G. J., KELLY, M., LANG, S., HOFMANN, P., ADDINK, E., ... & TIEDE, D. (2014). Geographic object-based image analysis—towards a new paradigm. *ISPRS journal of photogrammetry and remote sensing*, 87, 180-191.

Bourgoin, C., Betbeder, J., Couteron, P., Blanc, L., Dessard, H., Oszwald, J., ... & GOND, V. (2020). UAV-based canopy textures assess changes in forest structure from long-term degradation. *Ecological Indicators*, 115, 106386.

BRAZ, A. M., DE SOUZA BARROS, M. H., BRAZ, A. M., & GARCIA, P. H. M. (2017). Manejo e capacidade de uso das terras aplicando geotecnologias na bacia hidrográfica do córrego Lajeado Amarelo – Três Lagoas MS. *Cerrados*, 15(1), 237-264.

COCHRAN, W. G. (1977). *Sampling Techniques* (3rd ed.). New York: John Wiley & Sons.

CHOUDHRY, H., & O'KELLY, G. (2018). Precision forestry: a revolution in the woods. *Basic materials, paper & forest products*.

CIHLAR, J., XIAO, Q., CHEN, J., BEAUBIEN, J., FUNG, K. AND LATIFOVIC, R. (1998). Classification by progressive generalization: a new automated methodology for remote sensing multispectral data. *International Journal of Remote Sensing*, 19: 2685–2704.

CLEVE, C., KELLY, M., KEARNS, F. R., & MORITZ, M. (2008). Classification of the wildland–urban interface: A comparison of pixel-and object-based classifications using high-resolution aerial photography. *Computers, Environment and Urban Systems*, 32(4), 317-326.

DAINELLI, R., TOSCANO, P., DI GENNARO, S. F., & MATESE, A. (2021a). Recent advances in unmanned aerial vehicle forest remote sensing—A systematic review. Part I: A general framework. *Forests*, 12(3), 327.

DAINELLI, R., TOSCANO, P., GENNARO, S. F. D., & MATESE, A. (2021). Recent advances in Unmanned Aerial Vehicles forest remote sensing—A systematic review. Part II: Research applications. *Forests*, 12(4), 397.

DAVIS, B. R. I. A. N. (2017). *Refinement of a Aeronave remotamente pilotada-based method for estimating coarse woody debris and biomass residue following forest harvest* (Doctoral dissertation, University of Georgia).

DE FREITAS, M., SILVA, A. P., CANEVA, R. A., & BEIG, (1980). Avaliação e controle de qualidade em florestas de eucaliptos. Piracicaba: IPEF, 1980. 8p. (Circular Técnica, 91).

DE GRAAF, N. R., FILIUS, A. M., & SANTOS, A. H. (2003). Financial analysis of sustained forest management for timber: Perspectives for application of the CELOS management system in Brazilian Amazonia. *Forest Ecology and Management*, 177(1-3), 287-299.

DECEA. (2022). Tenha uma operação segura com sua aeronave não tripulada. Disponível em: < [https://www.decea.mil.br/Aeronave remotamente pilotada/](https://www.decea.mil.br/Aeronave%20remotamente%20pilotada/) > Acesso em: junho de 2022.

DECEA. (2022a). Bem-Vindo ao SARPAS - Solicitação de Acesso de Aeronaves Remotamente Pilotadas (RPAS). Disponível em: < <https://servicos.decea.mil.br/sarpas/> > Acesso em: junho de 2022.

DEFRIES, R. S. AND CHAN, J. C. (2000). Multiple criteria for evaluating machine learning algorithms for land cover classification from satellite data. *Remote Sensing of Environment*, 74: 503–515.

DHINGRA, S., & KUMAR, D. (2019). A review of remotely sensed satellite image classification. *International Journal of Electrical & Computer Engineering* (2088-8708), 9(3).

DIAS, N. O., MARTINS, F. C. M., & DE OLIVEIRA BARROS, K. (2020). Geotecnologia aplicada à diagnose ambiental: Reserva Biológica de Pinheiro Grosso, Barbacena–MG. *Sociedade & Natureza*, 32, 126-140.

DING, H., YAN, C., & HE, D. (2019). High-resolution Remote Sensing Image Semantic Segmentation with a Hybrid Deep Network. *IEEE Transactions on Geoscience and Remote Sensing*.

DINULICĂ, F., ALBU, C. T., VASILESCU, M. M., & STANCIU, M. D. (2019). Bark features for identifying resonance spruce standing timber. *Forests*, 10(9), 799.

DINIZ, C., SESSIONS, J., TIMOFEICZYK JUNIOR, R., & ROBERT, R. (2020). Equipment replacement policy for forest machines in Brazil. *International Journal of Forest Engineering*, 31(2), 87-94.

DROLET, S., & LEBEL, L. (2010). Forest harvesting entrepreneurs, perception of their business status and its influence on performance evaluation. *Forest Policy and Economics*, 12(4), 287-298.

DUDA, R. O., & HART, P. E. (1972). Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1), 11-15.

DUPUIS, C., LEJEUNE, P., MICHEZ, A., & FAYOLLE, A. (2020). How can remote sensing help monitor tropical moist forest degradation?—a systematic review. *Remote Sensing*, 12(7), 1087.

DYKSTRA, D. P., & HEINRICH, R. (1996). *FAO model code of forest harvesting practice*. FAO.

EMBRAPA. (2019). Embrapa Agrossilvipastoril: primeiras contribuições para o desenvolvimento de uma Agropecuária Sustentável / Austeclínio Lopes de Farias Neto... [et al.]. – Brasília, DF: Embrapa, 2019. PDF (825 p.), ISBN: 978-85-7035-905-6.

EMBRAPA. (2023). Classificação de solos. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/sistema-plantio-direto/agrossistemas/sistema-santanna/pre-producao/componentes/solos>> Acesso em: outubro de 2023.

EMBRAPA. (2023a). Clima. Disponível em: <<https://www.cppse.embrapa.br/meteorologia/index.php?pg=caracterizacao>> Acesso em: outubro de 2023.

FERREIRA, L. R. A., OTTO, R. B., SILVA, F. P., DE SOUZA, S. N. M., DE SOUZA, S. S., & JUNIOR, O. A. (2018). Review of the energy potential of the residual biomass for the distributed generation in Brazil. *Renewable and Sustainable Energy Reviews*, 94, 440-455.

FERREIRA, M. P., LOTTE, R. G., D'ELIA, F. V., STAMATOPOULOS, C., KIM, D. H., & BENJAMIN, A. R. (2021). Accurate mapping of Brazil nut trees (*Bertholletia excelsa*) in Amazonian forests using WorldView-3 satellite images and convolutional neural networks. *Ecological Informatics*, 63, 101302.

FIEDLER, N. C., CARMO, F. C. D. A. D., MINETTE, L. J., & SOUZA, A. P. D. (2017). Operational analysis of mechanical cut-to-length forest harvesting system. *Revista Árvore*, 41.

FOODY, G. M. (2008). Harshness in image classification accuracy assessment. *International Journal of Remote Sensing*, 29(11), 3137-3158.

GALAMHOS, C., MATAS, J., & KITTLER, J. (1999). Progressive probabilistic Hough transform for line detection. In Proceedings. 1999 IEEE computer society conference on computer vision and pattern recognition (Cat. No PR00149) (Vol. 1, pp. 554-560). IEEE.

GAMA, J. R. V., DE SOUZA, A. L., DA SILVA, M. L., DOS SANTOS VIEIRA, D., DE OLIVEIRA, M. L. R., FIGUEIREDO, A. E. S., & LAFETÁ, B. O. (2022). Financial viability of charcoal production in different forest management systems in Brazil. *Revista Forestal Mesoamericana Kurú*, 19(44).

GRASSO, M. (1998). Ecological-economic model for optimal mangrove trade off between forestry and fishery production: comparing a dynamic optimization and a simulation model. *Ecological modelling*, 112(2-3), 131-150.

GUERRA, S. P. S., OGURI, G., & SPINELLI, R. (2016). Harvesting eucalyptus energy plantations in Brazil with a modified New Holland forage harvester. *Biomass and Bioenergy*, 86, 21-27.

GUO, T., LIU, Y., & ZHU, F. (2020). A Novel Multispectral Image Segmentation Method Based on Convolutional Neural Networks. *Remote Sensing*, 12(9), 1475.

HÄGGSTRÖM, C., & LINDROOS, O. (2016). Human, technology, organization and environment—a human factors perspective on performance in forest harvesting. *International Journal of Forest Engineering*, 27(2), 67-78.

HAN, Y., REN, J., HONG, Z., ZHANG, Y., ZHANG, L., MENG, W., & GU, Q. (2015). Active learning algorithms for the classification of hyperspectral sea ice images. *Mathematical Problems in Engineering*, 2015.

HARALICK, R. M., SHANMUGAM, K., & DINSTEIN, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.

HE, T., ZHANG, Z., ZHANG, H., ZHANG, Z., XIE, J., & LI, M. (2019). Bag of tricks for image classification with convolutional neural networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 558-567).

HENGL, T. (2019). Everybody has a right to know what's happening with the planet: towards a global commons On the critical role of remote sensing, legacy field observations, Data Science and reproducible research for monitoring environment.

HOUGHLINES. (2023). HoughLines - Uses the Hough Transform technique to compute and display straight lines from a binary edge image. Disponível em: <<http://www.fmwconcepts.com/imagemagick/hoуглines/index.php>> Acesso em: outubro de 2023.

HOUGHLINESP. (2023). HoughLinesP - Straight line Hough transform. Disponível em: <https://scikit-image.org/docs/stable/auto_examples/edges/plot_line_hough_transform.html#id4> Acesso em: outubro de 2023.

HU, Y., XIA, G. S., ZHANG, L., BAI, X., & LATECKI, L. J. (2017). Webly Supervised Semantic Segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1372-1381.

HUNT JR, E. R., & DAUGHERTY, C. S. (2018). What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?. *International journal of remote sensing*, 39(15-16), 5345-5376.

IBA. (2023). Indústria Brasileira de Árvores - IBA. Relatórios Anuais: Relatório Anual 2022. Disponível em: <<https://iba.org/publicacoes>> Acesso em: outubro de 2023.

IBA. (2023a). Indústria Brasileira de Árvores - IBA. Cenários: Edição 68 - 4º trimestre 2022. Disponível em: <<https://iba.org/publicacoes/cenarios>> Acesso em: outubro de 2023.

IMANI, M., & GHASSEMIAN, H. (2020). An overview on spectral and spatial information fusion for hyperspectral image classification: Current trends and challenges. *Information fusion*, 59, 59-83.

INPE. (2023). Instituto Nacional de Pesquisas Espaciais – INPE. Sensoriamento Remoto. Disponível em: <http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html> Acesso em: outubro de 2023.

JACOVINE, L. A. G., Machado, C. C., Souza, A. P. D., Leite, H. G., & Minetti, L. J. (2005). Avaliação da qualidade operacional em cinco subsistemas de colheita florestal. *Revista Árvore*, 29, 391-400.

JACOVINE, L. A. G., REZENDE, J. L. P., SOUZA, A. P. D., LEITE, H. G., & TRINDADE, C. (1999). Descrição e uso de uma metodologia para avaliação dos

custos da qualidade na colheita florestal semimecanizada. *Ciência Florestal*, 9, 143-160.

JIAN, W. (2012). Unsupervised intrusion feature selection based on genetic algorithm and fcm. In *Information Engineering and Applications* (pp. 1005-1012). Springer, London.

JIANG, J., HUANG, L., LI, H., & XIAO, L. (2016). Hyperspectral image supervised classification via multi-view nuclear norm based 2D PCA feature extraction and kernel ELM. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 1496-1499). IEEE.

MATAS, J., GALAMBOS, C., & KITTNER, J. (2000). Robust detection of lines using the progressive probabilistic hough transform. *Computer Vision and Image Understanding*, 78(1):119–137, 2000.

JUNIOR, H. D. J. E., OGURI, G., DE MELO, R. X., BALLARIN, A. W., & GUERRA, S. P. S. (2016). Storage of whole-tree chips from high-density energy plantations of Eucalyptus in Brazil. *Biomass and Bioenergy*, 93, 279-283.

KELLNER, J. R., ARMSTON, J., BIRRER, M., CUSHMAN, K. C., DUNCANSON, L., ECK, C., ... & ZGRAGGEN, C. (2019). New opportunities for forest remote sensing through ultra-high-density Aeronave remotamente pilotada lidar. *Surveys in Geophysics*, 40(4), 959-977.

KIPF, T. N., & WELLING, M. (2016). Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*.

KIZHA, A. R., & HAN, H. S. (2015). Forest residues recovered from whole-tree timber harvesting operations. *European Journal of Forest Engineering*, 1(2), 46-55.

KIZHA, A. R., & HAN, H. S. (2016). Processing and sorting forest residues: Cost, productivity and managerial impacts. *Biomass and Bioenergy*, 93, 97-106.

Krishnapuram, B., Williams, D., Xue, Y., Carin, L., Figueiredo, M., & Hartemink, A. (2004). On semi-supervised classification. *Advances in neural information processing systems*, 17.

KUCHARCZYK, M., & HUGENHOLTZ, C. H. (2021). Remote sensing of natural hazard-related disasters with small Aeronave remotamente pilotada: Global trends, biases, and research opportunities. *Remote Sensing of Environment*, 264, 112577.

LEGOUT, A., HANSSON, K., VAN DER HEIJDEN, G., LACLAU, J. P., MARESCHAL, L., NYS, C., ... & RANGER, J. (2020). Chemical fertility of forest ecosystems. Part 2:

Towards redefining the concept by untangling the role of the different components of biogeochemical cycling. *Forest Ecology and Management*, 461, 117844.

LI, C., & WANG, J. (2019). "Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art." *IEEE Geoscience and Remote Sensing Magazine*, 7(4), 8-23.

LI, S., SONG, W., FANG, L., CHEN, Y., GHAMISI, P., & BENEDIKTSSON, J. A. (2019). Deep learning for hyperspectral image classification: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690-6709.

LI, Y., CHAI, G., WANG, Y., LEI, L., & ZHANG, X. (2022). Ace r-cnn: An attention complementary and edge detection-based instance segmentation algorithm for individual tree species identification using uav rgb images and lidar data. *Remote Sensing*, 14(13), 3035.

LI, Y., ZHANG, H., XUE, X., JIANG, Y., & SHEN, Q. (2018). Deep learning for remote sensing image classification: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(6), e1264.

LOPES QUEIROZ, G., MCDERMID, G. J., LINKE, J., HOPKINSON, C., & KARIYEVA, J. (2020). Estimating coarse woody debris volume using image analysis and multispectral LiDAR. *Forests*, 11(2), 141.

LU, D., & WENG, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International journal of Remote sensing*, 28(5), 823-870.

LV, W., & WANG, X. (2020). Overview of hyperspectral image classification. *Journal of Sensors*, 2020.

MA, L., LI, M., MA, X., CHENG, L., DU, P., & LIU, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277-293.

MAC DONAGH, P., BOTTA, G., SCHLICHTER, T., & CUBBAGE, F. (2017). Harvesting contractor production and costs in forest plantations of Argentina, Brazil, and Uruguay. *International Journal of Forest Engineering*, 28(3), 157-168.

MACHADO, C. C. Colheita Florestal. 3 ed., Viçosa: Editora UFV. 468. p. 2014

MARCHI, E., CHUNG, W., VISSER, R., ABBAS, D., NORDFJELL, T., MEDERSKI, P. S., ... & LASCHI, A. (2018). Sustainable Forest Operations (SFO): A new paradigm in a changing world and climate. *Science of the Total Environment*, 634, 1385-1397.

MARRA, E., WICTORSSON, R., BOHLIN, J., MARCHI, E., & NORDFJELL, T. (2021). Remote measuring of the depth of wheel ruts in forest terrain using a Aeronave remotamente pilotada. *International Journal of Forest Engineering*, 32(3), 224-234.

MICHALSKI, K., & GĘBICKI, M. (2019). The use of civil Aeronave remotamente pilotada in forest district logistics. *Transport Economics and Logistics*, 78, 133-146.

MILLER, Z., HUPY, J., HUBBARD, S., & SHAO, G. (2022). Precise Quantification of Land Cover before and after Planned Disturbance Events with UAS-Derived Imagery. *Aeronave remotamente pilotada*, 6(2), 52.

MIYAJIMA, R. H., FENNER, P. T., BATISTELA, G. C., & SIMÕES, D. (2021). Effect of Feller-Buncher Model, Slope Class and Cutting Area on the Productivity and Costs of Whole Tree Harvesting in Brazilian Eucalyptus Stands. *Forests*, 12(8), 1092.

MOU, L., LU, X., LI, X., & ZHU, X. X. (2020). Nonlocal graph convolutional networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12), 8246-8257.

MYINT, S. W., GOBER, P., BRAZEL, A., GROSSMAN-CLARKE, S., & WENG, Q. (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote sensing of environment*, 115(5), 1145-1161.

NAKAHATA, C., UEMURA, R., SAITO, M., KANETSUKI, K., & ARUGA, K. (2014). Estimating harvest costs and projecting quantities of logging residues for small-scale forestry in Nasushiobara, Tochigi Prefecture, Japan. *Journal of forestry research*, 25, 965-974.

OLIVEIRA, F., & SANTOS, J. (2020). "Impact of Post-Harvest Residue Management on Forest Sustainability: A Case Study in Brazil." *Journal of Forestry Management*, 45(2), 123-136.

OLIVEIRA, G. S., SOARES, P. R. C., & SAMPIETRO, J. A. (2020). Quality function deployment (QFD) applied to the variables that influence quality costs in mechanized forest harvest operations. *Floresta*, 50(4), 1717-1724.

OPENCV. (2023). OpenCV - Open Source Computer Vision Library. Disponível em: <<https://opencv.org/about/>> Acesso em: outubro de 2023.

OPENCV. (2023a). OpenCV - Canny Edge Detection. Disponível em: <https://docs.opencv.org/3.4/da/d22/tutorial_py_canny.html> Acesso em: outubro de 2023.

ORO, D., LOPES, E. D. S., RODRIGUES, C. K., DA SILVA, D. A., PELISSARI, A. L., & ROBERT, R. C. (2021). Productive assessment and energy balance of a horizontal

grinder of forest residues recovered from full tree pine harvesting. *International Journal of Forest Engineering*, 32(2), 185-190.

PÁDUA, L., ADÃO, T., HRUŠKA, J., SOUSA, J. J., PERES, E., MORAIS, R., & SOUSA, A. (2017). Very high resolution aerial data to support multi-temporal precision agriculture information management. *Procedia Computer Science*, 121, 407-414.

PAOLI, A., MELGANI, F., & PASOLLI, E. (2009). Clustering of hyperspectral images based on multiobjective particle swarm optimization. *IEEE transactions on geoscience and remote sensing*, 47(12), 4175-4188.

PENA-VERGARA, G., CASTRO, L. R., GASPARETTO, C. A., & BIZZO, W. A. (2022). Energy from planted forest and its residues characterization in Brazil. *Energy*, 239, 122243.

PEREIRA, R., & CARVALHO, M. (2021). "Economic and Environmental Impacts of Inadequate Post-Harvest Waste Management in Forest Operations: A Case Study in Europe." *Environmental Management*, 58(3), 214-227

PIOVAN, S. E. (2020). Remote Sensing. In *The Geohistorical Approach* (pp. 171-197). Springer, Cham.

POUDYAL, B. H., MARASENI, T., & COCKFIELD, G. (2018). Evolutionary dynamics of selective logging in the tropics: A systematic review of impact studies and their effectiveness in sustainable forest management. *Forest Ecology and Management*, 430, 166-175.

POWERS, R. P., HAY, G. J., & CHEN, G. (2012). How wetland type and area differ through scale: A GEOBIA case study in Alberta's Boreal Plains. *Remote Sensing of Environment*, 117, 135-145.

QGIS. (2023). QGIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation. Disponível em: <https://qgis.org>. Acesso em: outubro de 2023.

RIBEIRO, D., SANTOS, R., SHIBASAKI, A., MONTENEGRO, P., CARVALHO, H., & CALÇADA, R. (2020). Remote inspection of RC structures using unmanned aerial vehicles and heuristic image processing. *Engineering Failure Analysis*, 117, 104813.

ROCHA, Q. S., LIMA, R. C. A., MUNIS, R. A., PEREIRA, G., & SIMÕES, D. (2022). Economic viability of the whole tree harvest under conditions of uncertainty: a study in southeastern Brazil. *International Journal of Forest Engineering*, 1-8.

ROTILI, W. O., BRANDELERO, C., DE OLIVEIRA FORTES, F., PERIPOLLI, J. L. Z., DE VARGAS, F., & WERNER, V. (2022). Quality control of logs in semi-mechanized harvest. *Floresta*, 52(2), 351-358.

RSTUDIO. (2022). RStudio - What Makes RStudio Different. Disponível em: <<https://www.rstudio.com/>> Acesso em: outubro de 2022.

SALES, A., GONZÁLES, D. G. E., MARTINS, T. G. V., SILVA, G. C. C., SPLETOZER, A. G., TELLES, L. A. D. A., ... & LORENZON, A. S. (2019). Optimization of Skid Trails and Log Yards on the Amazon Forest. *Forests*, 10(3), 252.

SANEI BAJGIRAN, O., KAZEMI ZANJANI, M., & NOURELFATH, M. (2017). Forest harvesting planning under uncertainty: a cardinality-constrained approach. *International Journal of Production Research*, 55(7), 1914-1929.

SANTOS, M. B., & DE FARIA, K. M. S. (2017). Uso de modelagens espaciais para análise de risco a incêndio: análise preliminar para a região norte de Goiás. Os *Desafios da Geografia Física na Fronteira do Conhecimento*, 1, 5811-5815.

SANTOS, P. A. V. H. D., SILVA, A. C. L. D., ARCE, J. E., & AUGUSTYNCZIK, A. L. D. (2019). A mathematical model for the integrated optimization of harvest and transport scheduling of forest products. *Forests*, 10(12), 1110.

SERPE, E. L., FIGUEIREDO FILHO, A., & ARCE, J. E. (2018). Perdas volumétricas relativas à colheita florestal e seus reflexos econômicos. *BIOFIX Scientific Journal*, 3(1), 172-176.

SHAH, D., & SHRIVASTAVA, S. (2019). A Comparative Analysis of Different Techniques for Image Segmentation. *International Journal of Advanced Research in Computer Science*, 10(4), 294-300.

SHLEYMOVICH, M. P., MEDVEDEV, M. V., & LYASHEVA, S. A. (2017). Image analysis in unmanned aerial vehicle on-board system for objects detection and recognition with the help of energy characteristics based on wavelet transform. In *Optical Technologies for Telecommunications 2016* (Vol. 10342, pp. 294-304). SPIE.

SHOKIROV, S., SCHAEFER, M., LEVICK, S. R., JUCKER, T., BOREVITZ, J., ABDURAHMANOV, I., & YOUNGENTOB, K. (2021). Multi-platform LiDAR approach for detecting coarse woody debris in a landscape with varied ground cover. *International Journal of Remote Sensing*, 42(24), 9324-9350.

SILVA OLIVEIRA, G., MARTINS GARCIA, B., CASEMIRO SOARES, P. R., SATURNINO DA SILVA, M. T., ALBERTO SAMPIETRO, J., & CAVASSIN DINIZ, C.

C. (2019). Gestão da qualidade com ênfase no setor florestal. *Scientia Agraria Paranaensis*, 18(2).

SILVA, A., & COSTA, P. (2019). "The Importance of Post-Harvest Waste Monitoring in Forestry Operations: A Study in Portugal." *International Journal of Sustainable Forestry*, 35(4), 278-291.

SILVA, P. H. B. M. D., ARCE, J. E., LOCH, G. V., DAVID, H. C., & FIORENTIN, L. D. (2016). Forest harvest scheduling plan integrated to the road network. *Cerne*, 22(1), 69-76.

SIMA, H., LIU, P., LIU, L., MI, A., & WANG, J. (2018). Sparse representation classification based on flexible patches sampling of superpixels for hyperspectral images. *Mathematical Problems in Engineering*, 2018.

SIMIONI, F. J., DE ALMEIDA BUSCHINELLI, C. C., MOREIRA, J. M. M. Á. P., DOS PASSOS, B. M., & GIROTTI, S. B. F. T. (2018). Forest biomass chain of production: Challenges of small-scale forest production in southern Brazil. *Journal of Cleaner Production*, 174, 889-898.

SMITH, R., JOHNSON, L., & LEE, T. (2016). Understanding Gamma Correction. *Journal of Applied Mathematics*. doi: 10.1155/2016/8763543.

SOWA, J. M. (2014). Factors determining quality of timber harvesting in Poland. *Forestry Letters*, 106(4).

SPINELLI, R., VISSER, R., BJÖRHEDEN, R., & RÖSER, D. (2019). Recovering energy biomass in conventional forest operations: a review of integrated harvesting systems. *Current Forestry Reports*, 5(2), 90-100.

SRIRAM, R. (2021). Utilizing Random Forest Machine Learning Models to Determine Water Table Flood Levels through Volunteered Geospatial Information. DOI

STÅHL, G., RINGVALL, A., & FRIDMAN, J. (2001). Assessment of coarse woody debris: a methodological overview. *Ecological Bulletins*, 57-70.

STRANG, W. J. (1983). On the optimal forest harvesting decision. *Economic Inquiry*, 21(4), 576-583.

SUN, Y., YUAN, X., & LIU, J. (2019). "Hyperspectral Image Classification Using Convolutional Neural Network and Collaborative Representation-Based Features." *IEEE Transactions on Geoscience and Remote Sensing*, 57(3), 1552-1565

SUN, Z., WANG, X., WANG, Z., YANG, L., XIE, Y., & HUANG, Y. (2021). UAVs as remote sensing platforms in plant ecology: review of applications and challenges. *Journal of Plant Ecology*, 14(6), 1003-1023.

TALBOT, B., RAHLF, J., & ASTRUP, R. (2018). An operational UAV-based approach for stand-level assessment of soil disturbance after forest harvesting. *Scandinavian Journal of Forest Research*, 33(4), 387-396.

TANG, L., & SHAO, G. (2015). Aeronave remotamente pilotada remote sensing for forestry research and practices. *Journal of Forestry Research*, 26(4), 791-797.

TANUT, B., WARANUSAST, R., & RIYAMONGKOL, P. (2021). High Accuracy Pre-Harvest Sugarcane Yield Forecasting Model Utilizing Aeronave remotamente pilotada Image Analysis, Data Mining, and Reverse Design Method. *Agriculture*, 11(7), 682.

TEHRANY, M. S., PRADHAN, B., & JEBUV, M. N. (2014). A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*, 29(4), 351-369.

THIFFAULT, E., BARRETTE, J., PARÉ, D., TITUS, B. D., KEYS, K., MORRIS, D. M., & HOPE, G. (2014). Developing and validating indicators of site suitability for forest harvesting residue removal. *Ecological indicators*, 43, 1-18.

TOSCANO, G., RINNAN, Å., PIZZI, A., & MANCINI, M. (2017). The use of near-infrared (NIR) spectroscopy and principal component analysis (PCA) to discriminate bark and wood of the most common species of the pellet sector. *Energy & Fuels*, 31(3), 2814-2821.

TRINDADE, C. (1993). Desenvolvimento de um sistema de controle de qualidade para a atividade florestal 1993. 164f. Dissertação (Mestrado em Ciência Florestal) Universidade Federal de Viçosa, Viçosa, 1993.

TUIA, D., VOLPI, M., COPA, L., KANEVSKI, M., & MUÑOZ-MARI, J. (2011). A survey of active learning algorithms for supervised remote sensing image classification. *IEEE Journal of Selected Topics in Signal Processing*, 5(3), 606-617.

TUPINAMBÁ-SIMÕES, F., BRAVO, F., GUERRA-HERNÁNDEZ, J., & PASCUAL, A. (2022). Assessment of drought effects on survival and growth dynamics in eucalypt commercial forestry using remote sensing photogrammetry. A showcase in Mato Grosso, Brazil. *Forest Ecology and Management*, 505, 119930.

VASCONCELOS, K. C. D. A., & SILVA JUNIOR, A. D. (2021). Learning sustainability in the harvesting practices of a forest-based company. *RAM. Revista de Administração Mackenzie*, 22.

VISSE, R., & OBI, O. F. (2021). Automation and robotics in forest harvesting operations: Identifying near-term opportunities. *Croatian Journal of Forest Engineering: Journal for Theory and Application of Forestry Engineering*, 42(1), 13-24.

WANG, C., GUO, Z., WANG, S., WANG, L., & MA, C. (2015). Improving hyperspectral image classification method for fine land use assessment application using semisupervised machine learning. *Journal of Spectroscopy*, 2015.

WANG, D., LI, C., SONG, H., XIONG, H., LIU, C., & HE, D. (2020). Deep learning approach for apple edge detection to remotely monitor apple growth in orchards. *IEEE access*, 8, 26911-26925.

WANG, Z., & DU, B. (2021). Unified active and semi-supervised learning for hyperspectral image classification. *GeoInformatica*, 1-16.

WELLMANN, T., LAUSCH, A., ANDERSSON, E., KNAPP, S., CORTINOVIS, C., JACHE, J., ... & HAASE, D. (2020). Remote sensing in urban planning: Contributions towards ecologically sound policies?. *Landscape and Urban Planning*, 204, 103921.

WINDRIM, L., BRYSON, M., MCLEAN, M., RANDLE, J., & STONE, C. (2019). Automated mapping of woody debris over harvested forest plantations using uavs, high-resolution imagery, and machine learning. *Remote Sensing*, 11(6), 733.

WOODCOCK, C. E., LOVELAND, T. R., HEROLD, M., & BAUER, M. E. (2020). Transitioning from change detection to monitoring with remote sensing: A paradigm shift. *Remote Sensing of Environment*, 238, 111558.

WU, X., SHEN, X., CAO, L., WANG, G., & CAO, F. (2019). Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (UAV-LiDAR) data in planted forests. *Remote Sensing*, 11(8), 908.

XIA, J., WANG, Y., DONG, P., HE, S., ZHAO, F., & LUAN, G. (2022). Object-oriented canopy gap extraction from UAV images based on edge enhancement. *Remote Sensing*, 14(19), 4762.

YANPING, T. I. A. N., CHAO, T. A. O., ZHENG RONG, Z. O. U., ZHAOXIA, Y. A. N. G., & XIAOFEI, H. E. (2015). Semi-supervised graph-based hyperspectral image classification with active learning. *Acta Geodaetica et Cartographica Sinica*, 44(8), 919.

ZHANG, J., HU, J., LIAN, J., FAN, Z., OUYANG, X., & YE, W. (2016). Seeing the forest from Aeronave remotamente pilotada: Testing the potential of lightweight Aeronave remotamente pilotada as a tool for long-term forest monitoring. *Biological Conservation*, 198, 60-69.

ZHANG, J., LI, X., & XIE, W. (2018). A Study on Image Blurring Algorithm Based on Gaussian Blur. 2018 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS), 1-5.

ZHANG, L., XIA, G. S., WU, T., LIN, L., & TAI, X. C. (2016a). Deep learning for remote sensing image understanding. *Journal of Sensors*, 2016.

ZHANG, Q., LIU, Y., & CHEN, X. (2018a). "Hyperspectral Image Segmentation Based on Spectral-Spatial Information Fusion and Active Contour Model." *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4650-4665.

ZHOU, X., WANG, H., CHEN, C., NAGY, G., JANCSO, T., & HUANG, H. (2023). Detection of Growth Change of Young Forest Based on UAV RGB Images at Single-Tree Level. *Forests*, 14(1), 141.

ZHOU, Y., WANG, L., JIANG, K., XUE, L., AN, F., CHEN, B., & YUN, T. (2020). Individual tree crown segmentation based on aerial image using superpixel and topological features. *Journal of applied remote sensing*, 14(2), 022210-022210.

APÊNDICE A - Script

Script - Projeto Resíduos (Identificação e Quantificação de toras com dimensões comerciais)

Baixar MINICONDA - Atualizado (<https://docs.conda.io/en/latest/miniconda.html>)

Baixar PYTHON - Atualizado (<https://www.python.org/downloads/>)

Baixar VSCODE - Atualizado (<https://code.visualstudio.com/download>)

Aqui estão algumas observações sobre as etapas do código:

Instalação de bibliotecas: As bibliotecas necessárias estão sendo instaladas no início do código. Certifique-se de executar esses comandos apenas uma vez para evitar reinstalações desnecessárias.

Processamento da imagem: O código realiza várias etapas de pré-processamento na imagem, como conversão para escala de cinza, aplicação de filtro Gaussiano, correção gamma, entre outros, para melhorar a detecção de bordas.

Detecção de bordas: É utilizada a técnica de detecção de bordas Canny para identificar as bordas na imagem pré-processada.

Identificação de objetos (toras): A transformada de Hough probabilística é aplicada para detectar as linhas que representam as toras na imagem.

Reclassificação da imagem: A imagem é reclassificada para atribuir valores binários (0 ou 1) aos pixels que representam toras.

Quantificação das toras: A área basal e o volume das toras são calculados com base nas geometrias detectadas.

Salvamento dos resultados: Os resultados são salvos em um arquivo Excel, incluindo o comprimento, área basal e volume das toras, bem como o número total de toras.

Verificação das influências das bandas espectrais: A influência das diferentes bandas RGB na segmentação de objetos é analisada e exibida em um gráfico de barras.

Certifique-se de fornecer os caminhos corretos para as imagens de entrada e saída, bem como para o arquivo Excel onde os resultados serão salvos. Além disso, verifique se todas as bibliotecas necessárias estão instaladas corretamente.

Instalar bibliotecas e ferramentas necessárias para o processamento das imagens (uma vez somente)

pip **install** pyparsing==**2.4.7**

pip **install** pytesseract

python -m django --versão # **2.0.2**

python3 -m django --versão # **2.0.2**

pip **install** --upgrade django

pip3 **install** --upgrade django

```
python -m pip install -U scikit-image
conda install scikit-image
pip install scikit-image --upgrade
conda install -c anaconda numpy
# Solução de possível erro na biblioteca: numpy e skimage
#(https://stackoverflow.com/questions/54241226/importerror-cannot-import-name-
#validate-lengths)
pip install opencv-python
pip3 install opencv-python
pip install opencv-contrib-python
python -m pip install matplotlib
python -m pip install imageio
conda install -c anaconda urllib3
conda install mahotas
pip install mahotas
conda install -c conda-forge gdal
pip install shapely
pip install ndimage
#instalar cv2 (se necessário) (https://stackoverflow.com/questions/46610689/how-to-
#import-cv2-in-python3)
```

```
# Início do código para o processamento das imagens de drone
# Terminal “cmd” no VSCode para acessar o ambiente Python: Importar as bibliotecas
# necessárias
import numpy as np
import numpy
import cv2
import cv2 as cv
from gettext import install
import io
import mahotas
from scipy import ndimage as ndi
import matplotlib.pyplot as plt
```

```
import matplotlib.lines as mlines
from matplotlib import image as image
from skimage.io import imread
from skimage.util import img_as_ubyte
from skimage.feature import canny
from skimage.draw import line
from skimage.measure import label
from skimage import data
from skimage.transform import hough_line, hough_line_peaks
from skimage.transform import probabilistic_hough_line
from matplotlib import cm
from skimage.io import imsave
from PIL import Image
import os
import math
from osgeo import gdal
import shapely
from shapely.geometry import Polygon
import geopandas as gpd
import pandas as pd
from scipy import ndimage

# Caminho da imagem (Diretório das imagens de trabalho - mudar sempre que
necessário)
path_img9 = r"C:\Users\Documents\SHP\map_recorte_60.tif"
# Visualização prévia da imagem
img_ori = imread(path_img9)
plt.imshow(img_ori)
plt.show()

# Fazer a leitura da imagem (OpenCv2) para detecção de bordas
imgcv = cv2.imread(path_img9, cv2.IMREAD_COLOR) #Imagem de trabalho
# Ler dados georreferenciados da imagem pela ferramenta GDAL
ds = gdal.Open(path_img9) #Imagem de trabalho
```

```

# Início da segmentação dos objetos, detecção de bordas
# Converter a imagem em escala de cinza RGB pela "cv2.cvtColor"
gray = cv2.cvtColor(imgcv, cv2.COLOR_BGR2GRAY)
plt.imshow(gray)
plt.show()

# Filtro de suavização Gaussiano para melhorar a diferenciação de objetos (utilizar se a detecção de bordas pela escala cinza(gray) não foi suficiente ou tipo de solo/resíduo)
blur = cv2.GaussianBlur(imgcv, (5,5), 0)
plt.imshow(blur)
plt.show()

# Aplicar correção gamma (Filtro de brilho e contraste)
gamma = 1.5
invGamma = 1.0 / gamma
table = np.array([(i / 255.0) ** invGamma) * 255 for i in np.arange(0, 256)]).astype("uint8")
gamma_corr = cv2.LUT(blur, table)

# Aplicar uma escala RGB para melhorar o contraste na imagem
red = gamma_corr[:, :, 2]
green = gamma_corr[:, :, 1]
blue = gamma_corr[:, :, 0]
gray_gamma = cv2.addWeighted(red, 0.3, green, 0.3, 0)
gray_gamma = cv2.addWeighted(gray_gamma, 0.4, blue, 0.3, 0)
plt.imshow(gray_gamma)
plt.show()

# Aplicar índice de vegetação (NDVI) na imagem original para auxiliar na detecção de bordas (quando no solo há + vegetação e madeira)
nir_band = ds.GetRasterBand(4).ReadAsArray().astype(np.float32)
red_band = ds.GetRasterBand(3).ReadAsArray().astype(np.float32)
ndvi = (nir_band - red_band) / (nir_band + red_band)
ndvi[ndvi < 0] = 0 # Eliminar valores negativos
ndvi[ndvi > 1] = 1 # Eliminar valores maiores que 1
ndvi = (ndvi * 255).astype(np.uint8) # Converter para uint8
plt.imshow(ndvi)

```

```

plt.show()

#cv2.imwrite('caminho/para/ndvi.tif', ndvi) #Se for salvar o índice NDVI criado na
imagem

#Visualizar os valores mínimos e máximos da imagem a ser utilizada na função Canny
hist, bins = np.histogram(gray.ravel(), bins=256, range=[0, 256])
min_value = np.argmax(hist > 0)
max_value = 255 - np.argmax(hist[::-1] > 0)
print("Valor mínimo:", min_value)
print("Valor máximo:", max_value)

# Detectar bordas na imagem utilizando “cv2.canny” – canny detector pela OpenCv
edgess = cv2.Canny(gray_gamma, 150, 300, 5) #Valores minimos e máximos:
precisam ser alterados para diferentes sistemas (valor max. certamente é borda, valor
min. certamente não é borda)
edges = cv2.dilate(edgess, cv2.getStructuringElement(cv2.MORPH_RECT, (3, 3)))
#Realçar as bordas (remover ruidos da imagem gerada)

plt.imshow(edges)
plt.show()

# Salvar a imagem das bordas (para visualização posterior somente)
cv2.imwrite(r"C:\Users\Arthur\OneDrive\Imagens
Dexco\parcela_80\map_recorte_80_edges.tif", edges) #Alterar de acordo com o
diretório

# Detectar pixels que formam as geometrias lineares (toras) – Identificação pela
Transformada de Hough Probabilística “cv2.HoughLinesP”

lines = cv2.HoughLinesP(edges, 1, np.pi/180, 100, minLineLength=50,
maxLineGap=10) #Depende da imagem de borda (anterior) (Variar em
minLineLength=100, maxLineGap=20)

# Obter as informações de georreferenciamento da imagem para salvar a imagem
gerada nas mesmas projeções

# Recriar informações geoespaciais da imagem original
band = ds.GetRasterBand(1)

img = band.ReadAsArray() #Verificar depois com o HoughLinesP e Edges

# Dados da imagem original (pixel, projeção, extensão e dimensão)
geotransform = ds.GetGeoTransform()
print(geotransform)

geoprod = ds.GetProjection()
print(geoprod)

```

```

x_size = band.XSize
y_size = band.YSize
print(x_size, y_size)

# Criar uma imagem em branco com as mesmas dimensões e GeoTiff da imagem
# original (para salvar as toras detectadas)

blank_image = np.zeros((y_size, x_size), np.uint8)
blank_image = cv2.cvtColor(blank_image, cv2.COLOR_GRAY2RGB)
for line in lines:
    x1, y1, x2, y2 = line[0]
    cv2.line(blank_image, (x1, y1), (x2, y2), (0, 255, 0), 2) #A partir da segmentação de
    #objetos e bordas identificadas detecta os objetos semelhantes, ou seja as toras
    #(geometria linear)

# Reclassificar os pixels da “blank_image” em: 1 onde há toras e 0 onde não há toras
reclass_image = np.zeros((y_size, x_size), np.uint8)
for i in range(y_size):
    for j in range(x_size):
        if any(blank_image[i,j]):
            reclass_image[i,j] = 1
plt.imshow(reclass_image)
plt.show()

# Salvar imagem gerada (toras) com a atualização dos dados georreferenciados
driver = gdal.GetDriverByName("GTiff")
new_ds = driver.Create(r"C:\Users\Documents\SHP\map_reclass.tif", x_size, y_size,
3, gdal.GDT_Byte) #Atualizar o diretório onde será salvo e nome do arquivo da
#imagem

new_ds.SetGeoTransform(geotransform) #Resposta tem de ser '0' - sinal que foi
#gravado corretamente

new_ds.SetProjection(geoproj) #Resposta tem de ser '0' - sinal que foi gravado
#corretamente

new_ds.GetRasterBand(1).WriteArray(reclass_image) #Resposta tem de ser '0' - sinal
#que foi gravado corretamente

new_ds.FlushCache() #Para salvar a imagem gerada e armazenar os dados
#georreferenciados corretamente

# Visualizar a imagem final gerada

dataset = gdal.Open(r"C:\Users\ Documents\SHP\map_reclass.tif") #Alterar para o
#diretório que a imagem de toras foi salva

```

```

band1 = dataset.GetRasterBand(1) #Como a imagem possui três bandas (poderia ser
0, 1 ou 2 – tem de testar caso não rode no “1”)
data1 = band1.ReadAsArray()
plt.imshow(data1, cmap='gray')
plt.show()
#Quantidade de pixel na imagem
print("Imagen Original:", x_size * y_size, "pixels")
# verificar as informações georreferenciadas (status de compatibilidade)
saved_image = dataset #Imagen aberta na etapa de visualização
# Obter a transformação georreferenciada da imagem salva
saved_transform = saved_image.GetGeoTransform()
print(saved_transform)
# Comparar a transformação da imagem salva com a da imagem original (tem de estar
igual para posterior quantificação)
if saved_transform == geotransform:
    print('As informações georreferenciadas foram salvas corretamente.')
else:
    print('As informações georreferenciadas não foram salvas corretamente.')
#Quantificar Área (m2), Área basal (m2) e Volume (m3) dos resíduos (toras) detectados
na imagem (geometria lineares)
#Área de ocupação dos resíduos na imagem
area_toras_pixels = np.count_nonzero(reclass_image == 1) # Conta pixel com valor 1
(toras)
area_toras_metros_quadrados = area_toras_pixels * (res**2) # Calcular a área em
metros quadrados
print(area_toras_metros_quadrados)
#Quantificar volumetria dos objetos (toras)
# Converter a imagem reclassificada (reclass_image) em polígonos
labeled, num_features = ndimage.label(reclass_image)
polys = ndimage.find_objects(labeled)
# Criar um GeoDataFrame para os polígonos (Como uma tabela de atributos para
cada geometria linear detectada)
polygons = []
for idx, p in enumerate(polys, start=1):

```

```

coords = (p[1].start, p[0].start, p[1].stop, p[0].stop)
geom = Polygon([(coords[0], coords[1]), (coords[2], coords[1]), (coords[2],
coords[3]), (coords[0], coords[3])])
polygons.append({'id': idx, 'geometry': geom})

gdf = gpd.GeoDataFrame(polygons, crs=geoproj)

# Calcular o comprimento de cada geometria
gdf['comprimento_metros'] = gdf['geometry'].length/100
print(gdf['comprimento_metros'])

# Filtrar polígonos com comprimento maior ou igual a “1 metro” (Depende do nível de
escala que for trabalhar
gdf_filtered = gdf[gdf['comprimento_metros'] >= 1]
print(gdf_filtered)

# Calcular o diâmetro (DAP) com base na largura da geometria do objeto (políгоно)
gdf_filtered['DAP'] = (gdf_filtered['geometry'].apply(lambda geom: geom.bounds[2] -
geom.bounds[0]))/10
print(gdf_filtered['DAP'])

# Calcular o comprimento em metros (só para reordenar)
gdf_filtered['comprimento_metros'] = gdf_filtered['geometry'].length/100
print(gdf_filtered['comprimento_metros'])

#Contagem de toras
# Definir o valor mínimo de comprimento desejado (em metros)
comprimento_minimo = 1.0 # Altere conforme necessário
# Filtrar o DataFrame gdf_filtered com base no comprimento mínimo
toras_comprimento_superior = gdf_filtered[gdf_filtered['comprimento_metros'] >
comprimento_minimo]
# Contar o número de toras com comprimento superior ao valor mínimo
numero_toras_comprimento_superior = len(toras_comprimento_superior)
# Exibir o número de toras com comprimento superior ao valor mínimo
print("Número de toras com comprimento superior a", comprimento_minimo,
"metros:", numero_toras_comprimento_superior)

# Calcular a área basal para cada geometria linear filtrada
gdf_filtered['AreaBasal'] = ((np.pi * ((gdf_filtered['DAP'] / 2)**2))/40000) # Área basal
em m2

```

```

print(gdf_filtered['AreaBasal'])

# Calcular o volume para cada geometria linear filtrada
gdf_filtered['Volume'] = gdf_filtered['AreaBasal'] *  

(gdf_filtered['comprimento_metros']) # Volume em metros cúbicos
print(gdf_filtered['Volume'])

# Calcular o somatório de área basal e volume para toda a imagem
soma_area_basal = gdf_filtered['AreaBasal'].sum() # Somatório da área basal em m2
soma_volume = gdf_filtered['Volume'].sum() # Somatório do volume em metros cúbicos

# Criar um dicionário com os dados que serão inseridos na tabela de atributos do Excel
dados_excel = {

    'Comprimento (metros)': gdf_filtered['comprimento_metros'],
    'Área Basal': gdf_filtered['AreaBasal'],
    'Volume': gdf_filtered['Volume'],
    'Número de Toras (comprimento > 1m)': [numero_toras_comprimento_superior] *  

    len(gdf_filtered)
}

# Converter o dicionário em um DataFrame
df_excel = pd.DataFrame(dados_excel)

# Salvar o DataFrame em um arquivo Excel
caminho_excel = r'C:\caminho\para\o\diretorio\dados_toras.xlsx' # Altere o caminho  

conforme necessário
df_excel.to_excel(caminho_excel, index=False)
print("Tabela de atributos salva em:", caminho_excel)

# Verificar o volume e área basal total da imagem
print("Somatório de Área Basal:", soma_area_basal, "m2/ha")
print("Somatório de Volume:", soma_volume, "m3/ha")

# Influência das bandas espectrais da imagem na segmentação de objetos - Definir  

qual tem maior intensidade
# Carregue a imagem colorida
image = cv2.imread(path_img93) # Substitua pelo nome do caminho de sua imagem

```

```
# Divida a imagem em suas bandas RGB
blue, green, red = cv2.split(image)

# Aplique o detector de bordas Canny em cada banda separadamente
canny_blue = cv2.Canny(blue, 100, 200) # Ajuste os parâmetros conforme o tipo de
atributo e imagem de trabalho (mesmo valor da etapa de detecção de bordas)
canny_green = cv2.Canny(green, 100, 200)
canny_red = cv2.Canny(red, 100, 200)

# Calcule a média das intensidades de borda em cada banda
mean_intensity_blue = np.mean(canny_blue)
mean_intensity_green = np.mean(canny_green)
mean_intensity_red = np.mean(canny_red)

# Crie um gráfico de barras para mostrar as influências das bandas
bandas = ['Azul', 'Verde', 'Vermelho']
intensidades = [mean_intensity_blue, mean_intensity_green, mean_intensity_red]
plt.bar(bandas, intensidades)
plt.xlabel('Banda RGB')
plt.ylabel('Intensidade Média de Borda')
plt.title('Influência das Bandas RGB na Segmentação de Objetos (Canny Edge)')
plt.show()
```