



ORESTHES MÁRLON ALVES E SILVA

**MULTISENsoRES NA DETECÇÃO E QUANTIFICAÇÃO DE
DESfolHA POR LEPIDÓPTEROS DESfolHADORES EM
EUCALIPTAIS**

LAVRAS-MG

2025

ORESTHES MÁRLON ALVES E SILVA

**MULTISENsoRES NA DETECÇÃO E QUANTIFICAÇÃO DE DESFOLHA POR
LEPIDÓPTEROS DESFOLHADORES EM EUCALIPTAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-graduação em Entomologia, para a obtenção do título de Mestre.

Prof. Dr. Ronald Zanetti Bonetti Filho

Orientador

Prof. Dr. Alexandre dos Santos

Coorientador

**LAVRAS-MG
2025**

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados
informados pelo(a) próprio(a) autor(a).**

Silva, Oresthes Márlon Alves e.

Multissensores na detecção e quantificação de desfolha por lepidópteros
desfolhadores em eucaliptais / Oresthes Márlon Alves e Silva. - 2025.

41 p. : il.

Orientador: Ronald Zanetti Bonetti Filho

Coorientador: Alexandre dos Santos

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.

Bibliografia.

1. Sensoriamento remoto. 2. Desfolha e Monitoramento. 3. Satélites Sentinel. 4.
Silvicultura de precisão. 5. Eucalipto. I. Zanetti Bonetti Filho, Ronald. II. dos Santos,
Alexandre. III. Universidade Federal de Lavras. IV. Título.


ORESTHES MÁRLON ALVES E SILVA

**MULTISENsoRES NA DETECÇÃO E QUANTIFICAÇÃO DE DESFOLHA POR
LEPIDÓPTEROS DESFOLHADORES EM EUCALIPTAIS**

**MULTISENSORS FOR THE DETECTION AND QUANTIFICATION OF
DEFOLIATION BY DEFOLIATING LEPIDOPTERANS IN EUCALYPT
PLANTATIONS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-graduação em Entomologia, para a obtenção do título de Mestre.

Aprovada em 10 de março de 2025.
Prof. Dr. Ronald Zanetti Bonetti Filho
Prof. Dr. Alexandre dos Santos
Prof. Dr. Fausto Weimar Acerbi Junior
Dra. Bruna Nascimento de Vasconcellos

Documento assinado digitalmente
 RONALD ZANETTI BONETTI FILHO
Data: 10/06/2025 08:59:22-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Ronald Zanetti Bonetti Filho
Orientador

**LAVRAS-MG
2025**

AGRADECIMENTOS

A Deus, por me manter resiliente e com esperança diante dos desafios ao longo da jornada acadêmica.

Agradeço à Universidade Federal de Lavras (UFLA), à Escola de Ciências Agrárias de Lavras (ESAL), ao Departamento de Entomologia (DEN), e ao apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

Ao Conselho Nacional de Científico e Tecnológico – CNPq pelo auxílio financeiro.

À Eldorado Brasil Celulose pelo apoio de campo e auxílio financeiro para a condução do estudo.

Ao professor Dr. Ronald Zanetti, pelo apoio, estratégia e expertise, especialmente nos momentos difíceis, e pela confiança depositada. Sou muito grato por compartilhar sua vasta experiência e profissionalismo, servindo de exemplo. Além dos desafios superados, quero levar comigo sua amizade como orientador e um pouco de sua visão de mundo, compromissada, focada e incrivelmente analítica.

Ao professor Dr. Alexandre dos Santos, pela parceria e pela oportunidade de unir o sensoriamento remoto à entomologia, dando início à minha trajetória profissional na área. Sou grato por sua orientação.

À minha mãe, Maria Izabel, que, mesmo de longe, sempre torceu pelo meu sucesso. Sou imensamente grato pelo privilégio de ser seu filho e por saber que sempre pude contar com seu apoio para tornar este sonho possível.

Aos amigos Ezequiel Garcia, Iasmin Frossard, Wender Batista, Leinha e, em especial, à Nazareth de Gracia, por estarem ao meu lado nos momentos difíceis do mestrado e por me darem ânimo para continuar. Levarei para sempre a força e a motivação de seguir em frente.

Aos professores e funcionários do PRPG/UFLA que contribuíram para este momento. Agradeço.

Enfim, a todos que não foram citados, mas que de alguma forma direta ou indiretamente, contribuíram para que eu chegasse até aqui.

RESUMO

O cultivo de eucalipto desempenha um importante papel no setor florestal brasileiro, sendo a principal fonte de matéria-prima para papel, celulose e carvão vegetal. Entretanto, a produtividade pode ser comprometida pela ação de insetos-praga, como os lepidópteros desfolhadores, tornando o monitoramento dessas infestações uma etapa fundamental para o manejo sustentável. Nesse contexto, o sensoriamento remoto se destaca como uma alternativa promissora para estimar os danos causados por lagartas desfolhadoras. Neste estudo, imagens RGB de drone e fotografias hemisféricas de dossel foram usadas como referência de alta resolução, enquanto cenas dos satélites Sentinel-1 (SAR) e Sentinel-2 (óptico) forneceram cobertura espacial ampla para avaliar as áreas infestadas por lagartas, aplicando algoritmos de aprendizado de máquina para prever a extensão do impacto das pragas. Entre os algoritmos de aprendizado de máquina avaliados, incluindo Support Vector Machine (SVM) com diferentes núcleos, Random Forest (RF) em múltiplas configurações e Redes Neurais Artificiais (ANN) com diversas estruturas de camadas e neurônios, os modelos SVM e RF apresentaram os melhores desempenhos. Os menores valores de erro médio absoluto (MAE) foram obtidos pelas versões radial, polinomial e linear do SVM, bem como por diversas combinações de parâmetros da Random Forest. Em contrapartida, os modelos baseados em ANN apresentaram os maiores valores de erro, sugerindo menor capacidade de predição da cobertura do dossel nesse contexto. Os menores valores de erro médio absoluto (MAE) foram registrados pelos modelos SVM radial (MAE $\approx 0,10$), SVM linear (MAE $\approx 0,11$) e por diversas configurações da Random Forest (MAE variando entre 0,10 e 0,12), indicando maior precisão na predição da cobertura do dossel. Porém, os modelos baseados em ANN apresentaram os maiores valores de erro (MAE $> 0,30$), sugerindo menor desempenho nesse cenário. A utilização dessa abordagem permite a detecção e monitoramento de áreas infestadas por lagartas desfolhadoras, antecipação da tomada de decisão no controle de pragas, otimizando o manejo florestal, reduzindo perdas na produção e minimizando custos operacionais e impactos ambientais e está alinhado com as diretrizes de sustentabilidade de certificações ambientais, como o Forest Stewardship Council (FSC) e o Programa Brasileiro de Certificação Florestal (Cerflor).

Palavras-chave: sensoriamento remoto; aprendizado de máquina; cobertura do dossel; manejo sustentável; impacto ambiental.

ABSTRACT

Eucalyptus cultivation plays an important role in the Brazilian forestry sector, being the main source of raw material for paper, pulp, and charcoal. However, productivity can be compromised by insect pest, such as defoliating lepidopterans, making the monitoring of these infestations a fundamental step for sustainable management. In this context, remote sensing stands out as a promising alternative to estimate the damage caused by defoliating caterpillars. In this study, high-resolution reference data were obtained from drone RGB images and hemispherical canopy photographs, while scenes from Sentinel-1 (SAR) and Sentinel-2 (optical) satellites provided broad spatial coverage to assess areas infested by caterpillars. Machine learning algorithms were applied to predict the extent of pest impact. Among the evaluated algorithms—Support Vector Machine (SVM) with different kernels, Random Forest (RF) in multiple configurations, and Artificial Neural Networks (ANN) with various layer and neuron structures—SVM and RF demonstrated the best performance. The lowest mean absolute error (MAE) values were achieved by the radial, polynomial, and linear versions of SVM, as well as by various parameter combinations of Random Forest. Conversely, models based on ANN showed higher error values, indicating a lower predictive capacity for canopy coverage in this context. The smallest MAE values recorded were approximately 0.10 for SVM radial, 0.11 for SVM linear, and between 0.10 and 0.12 for various RF configurations, indicating higher accuracy in predicting canopy coverage. However, ANN-based models exhibited MAE values greater than 0.30, suggesting lower performance in this scenario. This approach enables the detection and monitoring of infested areas by caterpillars, facilitating early decision-making in pest control, optimizing forest management, reducing production losses, and minimizing operational costs and environmental impacts. It also aligns with sustainability guidelines of environmental certifications such as the Forest Stewardship Council (FSC) and the Brazilian Forest Certification Program (Cerflor).

Keywords: remote sensing; machine learning; canopy cover; sustainable management; environmental impact.

IMPACTOS SOCIAIS, TECNOLÓGICOS, ECONÔMICOS E CULTURAIS

O trabalho teve como objetivo avaliar o uso de tecnologias multissensoriais, incluindo imagens provenientes de satélites (Sentinel-1 e Sentinel-2), fotografias hemisféricas e drones, para detecção e quantificação da desfolha causada por lepidópteros desfolhadores em plantios de eucalipto. Os impactos tecnológicos são bem presentes, pois a metodologia proposta aplica sensoriamento remoto e algoritmos de aprendizado de máquina para classificar os níveis de dano foliar com precisão, promovendo inovação no monitoramento fitossanitário. Em termos econômicos, o uso dessas ferramentas pode reduzir os custos com mão de obra e produtos fitossanitários, pois permite ações mais localizadas, diminuindo perdas produtivas e promovendo o manejo sustentável. Socialmente, o trabalho possui potencial de extensão ao setor produtivo florestal brasileiro, especialmente em empresas que atuam no cultivo de eucalipto. A área de influência compreende as principais regiões produtoras de celulose, principalmente na região sudeste e centro-oeste, com possibilidade de ampliação para outras regiões produtoras do Brasil. Foram diretamente envolvidos dois estudantes de graduação, além do autor, do orientador e coorientador totalizando cinco participantes. O caráter extensionista do trabalho se expressa na possibilidade de transferência de tecnologia ao setor produtivo por meio da publicação dos resultados, desenvolvimento de ferramentas tecnológicas para a silvicultura de precisão e apresentações em eventos científicos. Os impactos ambientais estão presentes, uma vez que abordagem proposta contribui para a redução do uso de inseticidas químicos, alinhando-se a práticas sustentáveis e certificações florestais, como FSC e Cerflor. Dentre as oito áreas temáticas da Política Nacional de Extensão, o trabalho se enquadra em meio ambiente, tecnologia e produção e trabalho. Por fim, os impactos estão fortemente alinhados aos Objetivos de Desenvolvimento Sustentável da ONU, destacando-se os ODS 2 (fome zero e agricultura sustentável), ODS 9 (indústria, inovação e infraestrutura), ODS 12 (consumo e produção responsáveis), ODS 13 (ação contra a mudança global do clima) e ODS 15 (vida terrestre), contribuindo diretamente para o cumprimento da Agenda 2030 ao propor soluções tecnológicas e sustentáveis para o manejo integrado de pragas em florestas plantadas.

SOCIAL, TECHNOLOGICAL, ECONOMIC AND CULTURAL IMPACTS

The developed work aimed to evaluate the use of multisensor technologies, including imagery from satellites (Sentinel-1 and Sentinel-2), hemispherical photography, and drones, for the detection and quantification of defoliation caused by defoliator lepidopterans in eucalyptus plantations. The technological impact is significant, as the proposed methodology applies remote sensing and machine learning algorithms to accurately classify levels of foliar damage, promoting innovation in phytosanitary monitoring. Economically, the use of these tools can reduce labor and pesticide costs by enabling more localized actions, minimizing productive losses, and fostering sustainable management. Socially, the work has extension potential for the Brazilian forest production sector, especially in companies involved in eucalyptus cultivation. The area of influence includes the main pulp-producing regions, particularly in the Southeast and Central-West regions, with the possibility of expansion to other productive regions in Brazil. Two undergraduate students were directly involved, in addition to the author, the advisor, and the co-advisor, totaling five participants. The extensionist nature of the work is expressed in the potential transfer of technology to the production sector through the publication of results, development of technological tools for precision silviculture, and presentations at scientific events. The environmental impacts are also evident, as the proposed approach contributes to reducing the use of chemical insecticides, aligning with sustainable practices and forest certifications such as FSC and Cerflor. Among the eight thematic areas of the National Extension Policy, the work fits into environment, technology and production, and labor. Finally, the impacts are strongly aligned with the United Nations Sustainable Development Goals (SDGs), especially SDG 2 (zero hunger and sustainable agriculture), SDG 9 (industry, innovation, and infrastructure), SDG 12 (responsible consumption and production), SDG 13 (climate action), and SDG 15 (life on land), directly contributing to the fulfillment of the 2030 Agenda by proposing technological and sustainable solutions for the integrated management of pests in planted forests.

LISTA DE FIGURAS

Figura 1 – Locais de amostragem de dados na região leste do estado brasileiro de Mato Grosso do Sul (MS).	23
Figura 2 – Equipamentos de voo. A: Controle de voo. B: RPAS DJI. C: Controle. D: Câmera RGB	25
Figura 3- Gráfico de correlação entre a percentagem de desfolha estimada visualmente por monitores de campo e abertura do dossel (GLA) estimada por fotografia hemisférica da copa de eucalipto infestado por lagartas desfolhadoras.	29
Figura 4- Foto hemisférica do dossel de eucalipto com (A) 0% de desfolha e (B) entre 75 a 100% de desfolha por lagarta desfolhadora.....	30
Figura 5- Gráfico de Bland-Altman.....	31
Figura 6- Histograma da distribuição da cobertura do dossel (CC) de eucalipto infestado com lagartas desfolhadoras, variando de 0 a 100%, utilizado para avaliar a suficiência do intervalo de dados.	313
Figura 7. Comparação do desempenho dos modelos por meio do erro médio absoluto (MAE), utilizando o teste de ordenação pairwise.t.test com correção de Bonferroni para avaliar diferenças estatísticas entre as médias.	34

LISTA DE TABELAS

Tabela 1. Parâmetros de voo com o drone.....	26
Tabela 2. Dados comparativos Sentinel-1 e Sentinel-2.....	28

SUMÁRIO

1	INTRODUÇÃO	12
2	OBJETIVOS	14
2.1	Objetivo Geral	14
2.2	Objetivos Específicos	14
3	HIPÓTESE	14
4	REFERENCIAL TEÓRICO	15
4.1	Características gerais da cultura do eucalipto.....	15
4.2	Lagartas desfolhadoras	16
4.3	Monitoramento e nível de controle para lagartas desfolhadoras	17
4.4	GLA (Gap Light Analyzer)	18
4.5	Manejo florestal de precisão e sua contribuição em plantações de eucalipto	19
4.6	Satélites Sentinel-1 e Sentinel-2	21
4.7	Aprendizado de Máquina (Machine learning)	21
5	MATERIAIS E MÉTODOS	22
	<i>Local de execução do estudo</i>	22
	<i>Seleção dos pontos amostrais</i>	23
	<i>Medição da desfolha</i>	23
	<i>Coleta de fotografias hemisféricas</i>	24
	<i>Coleta de imagens RGB com drone</i>	24
	<i>Processamento das imagens do drone</i>	26
	<i>Coleta e processamento das imagens do Sentinel 1 e 2</i>	27
	<i>Análise estatística</i>	28
6	RESULTADOS E DISCUSSÃO	29
	<i>Relação entre avaliação visual e fotográfica hemisférica na estimativa da desfolha</i>	29
	<i>Estimativa da desfolha utilizando Sentinel-1 e Sentinel-2 e aprendizado de máquina</i>	32
7	CONCLUSÃO	35
	REFERÊNCIAS	35

1 INTRODUÇÃO

Os danos ocasionados por pragas constituem um dos principais fatores responsáveis pela redução da produtividade e pelos prejuízos nas atividades agroflorestais, sendo o monitoramento dessas populações um elemento-chave na prevenção de perdas (SANTOS et al, 2004). Em particular, os plantios de eucalipto no Brasil enfrentam grandes desafios, devido à vasta extensão das áreas cultivadas, o que torna importante a implementação de sistemas de monitoramento que sejam contínuos, otimizados e aplicáveis em larga escala (SOLIMAN, 2014).

As lagartas desfolhadoras são pragas de grande impacto, causando danos diretos à capacidade fotossintética das árvores, o que compromete o crescimento e o rendimento da cultura. Além disso, o comportamento dos lepidópteros agrava o problema, pois dispersam-se por longas distâncias, originando novos focos de infestação (ANJOS et al, 1996). Esses insetos, embora apresentem surtos sazonais de curta duração, desfolham os talhões em questão de semanas, afetando diretamente a produtividade (IBÁ, 2020).

Diante disso, a busca por soluções que combinem rapidez, precisão e ampla cobertura espacial é fundamental para reduzir os custos de controle, minimizar perdas econômicas e possibilitar a aplicação de práticas sustentáveis de manejo florestal (MUTANGA, 2017). No entanto, métodos convencionais de monitoramento com avaliações visuais em campo, carecem de eficiência para detectar os danos precocemente, apontando a necessidade de sistemas baseados em tecnologias avançadas, como o uso de sensores remotos para detecção e análise em larga escala (JAROLMASJED, 2019).

O sensoriamento remoto (SR) é uma abordagem que visa coletar informações sobre um objeto sem a necessidade de contato direto, permitindo identificar fenômenos em plantios de eucalipto com maior agilidade, cobrindo grandes áreas e superando as limitações dos métodos convencionais de monitoramento (PARANHOS et al, 2021). Quando comparado com o trabalho realizado pelos monitores de campo, responsáveis por observar sinais de pragas ou doenças, o SR se destaca por facilitar essa atividade, que seria desafiadora devido à necessidade de inspecionar manualmente toda a área. (KUMBULA et al, 2019). A diversidade de dados de sensoriamento remoto (SR), provenientes de sensores passivos ópticos, ativos de radar (SAR) e LIDAR, viabiliza análises em múltiplas escalas e níveis de aquisição, fator decisivo para o monitoramento florestal de precisão (PARANHOS et al, 2021). Sensores orbitais, como os da série Sentinel, oferecem ampla cobertura espacial e elevada frequência temporal, atendendo a demandas de detecção regional e acompanhamento de tendências (SEGARRA et al., 2020). Já os sistemas aerotransportados e as Aeronaves Remotamente Pilotadas (RPA) possibilitam

resoluções espaciais submétricas, essenciais para a validação em campo e o detalhamento de microvariações na estrutura do dossel (THOMPSON; SHI; FERGUSON, 2017). A integração desses diferentes níveis de aquisição (satélite, aéreo e drone) combinada às resoluções espectral, espacial e temporal adequadas, potencializa a identificação precoce de distúrbios, otimiza estratégias de amostragem e reduz incertezas inerentes aos métodos convencionais (LILLESAND; KIEFER; CHIPMAN, 2015; JENSEN, 1996).

Dentro desse contexto, os satélites Sentinel-1 e Sentinel-2 se destacam no monitoramento de pragas florestais (SPRACKLEN & SPRACKLEN, 2021). O satélite Sentinel-1, é uma constelação de satélites de radar de abertura sintética (SAR) que opera em todas as condições meteorológicas dia e noite, utilizando radares de banda C (5,405 GHz), permitindo a observação contínua de regiões com cobertura de nuvens frequente (SEGARRA, 2020). Já o Sentinel-2 oferece imagens de média resolução espacial de 10 metros em sua melhor resolução e alta frequência temporal, permitindo monitoramento frequente de áreas extensas (SPRACKLEN & SPRACKLEN, 2021). Adicionalmente, essas imagens quando processadas com técnicas avançadas de aprendizado de máquinas (*Machine learning*), como *Support Vector Machine* (SVM), *Random Forest* (RF) e *Classificação Naïve Bayes* (NB), possibilitam a extração de padrões complexos nos dados e a identificação precisa das áreas impactadas (SEGARRA et al., 2020).

O uso de Aeronaves Remotamente Pilotadas (RPA), conhecidas como “drones”, também complementa essas abordagens, permitindo missões programáveis com sensores multiespectrais. Esses equipamentos são capazes de superar desafios como nuvens ou questões temporais e oferecem uma solução acessível e eficiente para o monitoramento em alta resolução de áreas críticas (THOMPSON; SHI; FERGUSON, 2017). Ao integrar dados obtidos pelos satélites Sentinel-1 e Sentinel-2, com tecnologias como *machine learning* e drones, é possível desenvolver sistemas de monitoramento precisos, capazes de minimizar impactos econômicos e ambientais em plantações comerciais de eucalipto.

Diante das características específicas desses lepidópteros em plantios de eucalipto, como focos de infestação em larga escala, ciclo curto de reprodução e método de amostragem em campo, torna-se necessário o desenvolvimento de novas técnicas de monitoramento para uma detecção eficiente (MARTÍNEZ PRENTICE et al., 2024).

2 OBJETIVOS

2.1 Objetivo Geral

Este trabalho teve como objetivo avaliar a eficácia do sensoriamento remoto em entregar estimativas precisas e operacionalmente úteis da intensidade e da área desfolhada em eucaliptais por meio de fotografias hemisféricas, imagens RGB (Red, Green, Blue), correspondentes às bandas vermelha, verde e azul do espectro visível) de drones e imagens dos satélites Sentinel-1 e Sentinel-2.

2.2 Objetivos Específicos

- Avaliar a eficácia de fotografias hemisféricas na estimativa da percentagem de desfolha causada por lagartas desfolhadoras em eucaliptais, em comparação com avaliação tradicional de notas visuais por operadores em campo.
- Detectar e estimar a percentagem de desfolha do dossel das plantas de eucalipto causada por lepidópteros desfolhadores, utilizando imagens dos satélites Sentinel-1 e Sentinel-2 combinados a imagens RGB de alta resolução obtidas com drones RPAS;
- Aplicar algoritmos de *machine learning* em imagens satélites a partir da calibração e treino com imagens RGB para analisar e quantificar a percentagem de desfolha causada por lagartas desfolhadoras em áreas infestadas

3 HIPÓTESE

- 1) As fotografias hemisféricas são tão efetivas quanto a avaliação visual para estimar a percentagem de desfolha causada por lagartas desfolhadoras em eucaliptais.
- 2) As imagens geradas pelos satélites Sentinel-1 e Sentinel-2 processadas pelos algoritmos *Machine learning* com imagens com drones RPAS permitem estimar a percentagem de desfolha causadas por lagartas desfolhadoras na cultura de eucalipto.

4 REFERENCIAL TEÓRICO

4.1 Características gerais da cultura do eucalipto

O eucalipto (*Eucalyptus sp.*), pertencente à família Myrtaceae, é uma árvore de crescimento rápido amplamente cultivada para fins industriais, com ciclos de produção que variam de 6 a 12 anos, dependendo da espécie e das condições de manejo (VERA et al., 2022). No início do ciclo, a planta passa por uma fase de estabelecimento, onde ocorre o desenvolvimento de raízes profundas e ramos vegetativos, fundamentais para o suporte estrutural e absorção de água e nutrientes (RODRIGUES et al, 2024). Durante o primeiro ano, há um crescimento intensivo dos ramos e folhas, que maximiza a capacidade fotossintética e promove o acúmulo de biomassa (OLIVEIRA et al., 2015). A partir do segundo ano, o eucalipto entra em um estágio de crescimento mais estável, no qual o desenvolvimento do tronco é priorizado, aumentando em diâmetro e altura, o que é crucial para a produção de madeira e fibras (OLIVEIRA et al., 2015). Nos anos subsequentes, o crescimento se torna mais uniforme, e a planta mantém um padrão regular de desenvolvimento até o período de maturação, quando ocorre a senescência de ramos mais antigos e a renovação foliar (MILHOMEM et al., 2023). Finalmente, ao término do ciclo, a árvore pode ser colhida para a extração de madeira, celulose ou carvão, reiniciando o processo com novos plantios (RODRIGUES et al, 2024).

O eucalipto possui grande relevância para o setor florestal brasileiro e para o agronegócio, sendo uma das principais culturas voltadas à produção de madeira, celulose e carvão vegetal (MILHOMEM et al., 2023). O país dispõe de condições geográficas e climáticas ideais para o cultivo de eucalipto, que, somadas aos incentivos em pesquisa e desenvolvimento, permitem grandes avanços em produtividade e sustentabilidade na cultura (OLIVEIRA et al., 2015). Os principais estados produtores de eucalipto no Brasil incluem Minas Gerais, São Paulo, Mato Grosso do Sul, Bahia e Espírito Santo (VERA et. al 2022).

Além disso, o setor florestal brasileiro tem se destacado pela adoção de práticas sustentáveis, alinhadas com certificações internacionais, como FSC e Cerflor, o que fortalece a competitividade do eucalipto brasileiro no mercado global (SILVA; NASCIMENTO, 2013).

Atualmente, o Brasil é um dos maiores exportadores de celulose derivada de eucalipto e continua expandindo sua participação em mercados estratégicos, especialmente na Ásia e na Europa, consolidando o país como líder na indústria florestal mundial (PEREIRA; SILVA JUNIOR, 2024).

Por ser um dos principais produtos florestais de alto valor agregado, com grande potencial de crescimento, o eucalipto também está sujeito a diversos fatores que podem limitar seu desenvolvimento, como ataques de pragas, doenças, variabilidade climática, entre outros (HALL et al., 2017). Entre esses fatores limitantes, as pragas têm um papel significativo, especialmente no Brasil, onde o cultivo de eucalipto enfrenta ameaças constantes de insetos desfolhadores, que comprometem a produtividade e a qualidade da madeira (HALL et al., 2017).

4.2 Lagartas desfolhadoras

Os insetos desfolhadores são os agentes que mais causam danos nos plantios florestais (SOLIMAN, 2014). As lagartas apresentam características diferentes dos outros agentes, como os coleópteros desfolhadores e formigas cortadeiras. Elas consomem completamente o limbo foliar, com ataque de baixo para cima, enquanto os coleópteros perfuram as folhas em qualquer parte da planta e as formigas cortadeiras devoram completamente o limbo foliar, atacando de cima para baixo (LEMES; ZANUNCIO, 2021).

Nos últimos anos, entre as espécies de lepidópteros, *Iridopsis panopla* tem se destacado por surtos cada vez mais frequentes, principalmente nos estados do Maranhão, Minas Gerais, São Paulo e Mato Grosso do Sul, sendo este último o estado onde a praga é mais dominante (SANTOS, 2023). A sua presença se manifesta por meio da raspagem e do consumo das folhas da planta, podendo causar desfolha completa da copa em função da densidade populacional e das práticas de manejo adotadas (LEMES; ZANUNCIO, 2021).

Morfologicamente, o gênero *Iridopsis sp.* se distingue pelas características dos genitais masculinos, com a valva dividida em dois lóbulos, onde uma mancha nas asas anteriores também pode ser utilizada como característica diagnóstica, porém não é presente em todas as espécies (PITKIN, 2002). Em análises filogenéticas moleculares recentes de Geometridae do Novo Mundo, as espécies de *Iridopsis sp.* formaram um grupo monofilético robusto, pertencente à tribo Boarmiini, com estreita relação filogenética com o gênero *Neofidonia Warren*, 1904, incluindo *Perigramma Guenée*, 1858, e *Stenoporpia McDunnough*, 1920 (BREHM et al., 2019).

O conhecimento sobre a diversidade do gênero *Iridopsis* ainda é limitado. Em plantios comerciais de eucalipto nos municípios de Três Lagoas e Brasilândia, no estado de Mato Grosso do Sul, pupas do gênero foram coletadas para análise e por meio de técnicas moleculares, a espécie foi determinada como *Iridopsis panopla*. Prout, 1932 (Lepidoptera: Geometridae), representando o primeiro registro dessa espécie no Brasil (SANTOS et al., 2021).

4.3 Monitoramento e nível de controle para lagartas desfolhadoras

O monitoramento sistemático das populações de insetos permite acompanhar a evolução populacional ao longo do tempo e direcionar as estratégias de manejo de forma mais racional no contexto do Manejo Integrado de Pragas (MIP) (GALLO et al., 2002). A avaliação contínua e o conhecimento da dinâmica desses artrópodes reduzem aplicações indiscriminadas e equilibra custos, especialmente para o controle de lagartas desfolhadoras (MORAIS et al., 1993; SILVA et al., 2017).

Para facilitar essa análise, o MIP estabeleceu diferentes níveis de alerta com base na média quinzenal de lepidópteros capturados por armadilha, com situação normal menos de 5 indivíduos/armadilha, situação de alerta, entre 5 e 100 indivíduos/armadilha situação de vistoria, entre 100 e 3.000 indivíduos/armadilha (LEMES; ZANUNCIO, 2021). Nesse último caso, é recomendando o monitoramento dos talhões afetados para avaliar a presença e a quantidade de lagartas (LEMES; ZANUNCIO, 2021).

A quantificação das lagartas desfolhadoras é feita por dois métodos visuais em campo, que são por meio do número de lagartas por 100 folhas e percentagem de desfolha (ZANUNCIO et al., 2014). No primeiro método, devem-se alocar três parcelas no ponto crítico de infestação (maior severidade aparente) e mais três parcelas nos pontos de intensidade mediana (ZANUNCIO et al., 2014). As parcelas devem ser alocadas de forma representativa e aleatória. Cada parcela será composta de três repetições, sendo cada uma constituída por uma árvore. Coleta-se, no terço médio-inferior de cada árvore, um ramo representativo para avaliar o número de lagartas pequenas (<3 cm) e grandes (>3 cm) e o número de folhas por ramo. Para isso, deve-se estender uma lona embaixo da árvore, utilizar um podão com haste telescópica e remover o ramo com o máximo cuidado para evitar a saída dos insetos (ZANUNCIO et al., 1993). Com os dados, calcula-se o número de lagartas/100 folhas = número de lagartas / número de folhas x 100. Depois, calcula-se a média do número de lagartas/100 folhas. O nível de controle varia de 6 a 8 lagartas/100 folhas (ZANUNCIO et al., 1993).

O método de percentagem de desfolha usa a mesma metodologia de locação das parcelas, porém avalia o nível de desfolha das árvores, conforme uma escala visual de notas: 0%, 25%, 50%, 75% e 100% da copa com sinais de desfolha. Depois, calcula-se a média da percentagem de copa com desfolha. O nível de controle é 25% de copa com desfolha (ZANETTI, 2006). As duas maneiras de avaliação podem ser feitas simultaneamente, uma vez que algumas espécies de lagartas passam o dia nas copas e outras na base do tronco (ZANUNCIO et al., 1993). Dessa forma, a avaliação conjunta é mais assertiva do que cada uma isoladamente.

4.4 GLA (Gap Light Analyzer)

O Gap Light Analyzer (GLA) é um software especializado em análise de abertura de dossel (canopy openness) e radiação luminosa, baseado em fotografias hemisféricas que capturam a estrutura da vegetação (FRAZER; CANHAM; LERTZMAN, 1999). Essas imagens, também conhecidas como “fisheye”, oferecem uma visão panorâmica do dossel florestal, permitindo estimar a disponibilidade de luz e quantificar a proporção de céu visível. No contexto do manejo florestal, especialmente em plantações de eucalipto, o GLA surge como uma ferramenta relevante para monitorar e avaliar impactos de danos bióticos, como o ataque de lagartas desfolhadoras, por meio da correlação entre a taxa de desfolha e o aumento na abertura do dossel.

Nas plantações de eucalipto, surtos de lagartas desfolhadoras podem resultar grandes perdas de produtividade, pois essas pragas se alimentam das folhas e comprometem a fotossíntese, atrasando o crescimento das árvores (ZANUNCIO et al., 2014; ZANETTI et al., 2000). O uso do GLA possibilita detectar essas perdas, uma vez que, ao aumentar a intensidade do ataque, maiores espaços ficam expostos no dossel, elevando a fração de luz incidente no sub-bosque (SILVA et al., 2017). Assim, ao comparar fotografias hemisféricas em diferentes estágios de desenvolvimento da infestação, é possível verificar se o grau de desfolha está avançando, bem como identificar áreas prioritárias para intervenção.

A aplicação prática do GLA consiste em registrar fotografias hemisféricas em pontos representativos da floresta, garantindo padronização no posicionamento da câmera, horário de coleta (geralmente em condições de céu nublado ou início/final do dia) e ângulo de captura (FRAZER; CANHAM; LERTZMAN, 1999). Após a coleta, essas imagens são processadas no software, que calcula indicadores como a porcentagem de abertura do dossel e a radiação fotossinteticamente ativa (PAR) potencial no sub-bosque. Em plantações de eucalipto sob manejo integrado de pragas (MIP), esses indicadores podem ser correlacionados com dados de campo, como o número de lagartas por folha ou porcentagem de desfolha, aumentando a precisão na detecção de surtos.

Uma das vantagens do GLA é a sensibilidade a pequenas alterações na estrutura do dossel. Isso significa que mesmo variações pontuais, provocadas por ataques iniciais de lagartas, podem ser detectadas antes que a infestação alcance níveis críticos. Além disso, ao integrar as informações de abertura de dossel às metodologias clássicas de avaliação (contagem de lagartas por 100 folhas ou porcentagem de desfolha), o monitoramento torna-se mais robusto e abrange tanto a quantificação direta dos insetos quanto a alteração efetiva na condição luminosa da floresta. Essa abordagem integrada também pode ser cruzada com índices de

vegetação, como o NDVI, fornecidos por drones ou satélites, otimizando o diagnóstico em nível regional (SOUZA, 2021).

Todavia, o uso do GLA apresenta algumas limitações que devem ser consideradas. Fatores como variação de topografia, luz direta do sol nos horários de coleta, presença de nuvens esparsas e a necessidade de padronizar o equipamento fotográfico podem interferir na qualidade das imagens e, conseqüentemente, nos índices calculados (FRAZER; CANHAM; LERTZMAN, 1999). Além disso, o método tradicionalmente demanda deslocamento em campo para realizar a captura das fotografias, o que pode ser um desafio em grandes áreas ou em locais de difícil acesso. Ainda assim, alguns estudos apontam para a possibilidade de integração do GLA com imagens adquiridas por aeronaves remotamente pilotadas (RPA), embora essa prática ainda requeira padronização de protocolos e equipamentos (DOMINGOS, 2017).

4.5 Manejo florestal de precisão e sua contribuição em plantações de eucalipto

Apesar da eficiência dos métodos tradicionais de monitoramento de lagartas no campo, o sensoriamento remoto (SR) tem se destacado como uma ferramenta estratégica para otimizar esse processo. Ele possibilita uma avaliação em larga escala, cobrindo extensas áreas de cultivo de forma ágil, auxiliando a identificar padrões característicos de desfolha, como o ataque progressivo com índices espectrais como o NDVI para diferenciar áreas saudáveis das afetadas. (CLARO FILHO; CONCEIÇÃO; RIBEIRO FILHO, 2007).

O sensoriamento remoto (SR) utiliza sensores para captar e registrar, à distância e sem contato direto, a energia refletida ou absorvida pela superfície da Terra (PARANHOS et al, 2021). Além do SR, existem outras geotecnologias empregadas na silvicultura de precisão que auxiliam na detecção de variabilidade espacial no campo, tais como os Sistemas de Informação Geográfica (SIG), o Sistema Global de Navegação por Satélite (GNSS), sensores de solo, planta e produtividade, e dispositivos para aplicação em taxa variável, entre outros, que contribuem para a coleta de dados e oferecem suporte específico para o manejo (ABD EL-GHANY; ABD EL-AZIZ; MAREI, 2020). Entre os principais benefícios do SR tem-se a análise temporal, que permite acompanhar a evolução dos surtos ao longo do tempo, gerando dados para antecipar a progressão dos danos e planejar ações preventivas (HALL et al., 2017). Além de complementar o PC-MIP, o SR pode ser integrado a modelos de *Machine Learning*, para otimizar a detecção de áreas infestadas e ampliar a precisão do monitoramento (PARANHOS et al, 2021). Tecnologias como drones equipados com sensores multiespectrais também oferecem análise em tempo real, possibilitando respostas mais direcionadas em áreas de maior risco. (ASSIS; MAYCON; PEREIRA, 2021).

O manejo florestal de eucalipto requer um monitoramento constante para identificar e antecipar possíveis problemas, como pragas, doenças e estresse hídrico, que podem impactar a produtividade (ASSIS; MAYCON; PEREIRA, 2021).

Nesse aspecto, o SR traz precisão ao utilizar satélites em órbita equipados com sensores que capturam dados em diferentes resoluções espaciais. Nos plantios de eucalipto, as imagens de média e alta resolução fornecidas permitem não apenas o acompanhamento do desenvolvimento das árvores, mas a detecção de anomalias na cobertura vegetal e a avaliação da saúde da floresta em larga escala (WANTROBA, et al., 2023). Esse tipo de acompanhamento tem sido aplicado com sucesso em casos práticos no manejo integrado de pragas em plantações de eucalipto. Por exemplo, o uso de SR para identificar infestações de *Thyrnteina arnobia*, possibilitando ações de controle direcionadas e econômicas (PONZONI, 1998). Em outro caso, imagens de satélites de alta resolução foram usadas para detectar o avanço de surtos de *Gonipterus spp.*, um besouro que se alimenta de folhas jovens, auxiliando na resposta rápida e na redução dos danos antes que comprometessem grandes áreas de plantio (WANTROBA, et al., 2023).

Embora o sensoriamento remoto (SR) ofereça diversas vantagens, sua aplicação pode ser limitada em algumas situações, como na análise de déficit nutricional, monitoramento regular do crescimento dos plantios, entre outros (CRUSIOL et al., 2024). Além disso, há imagens obtidas por satélites pagos que apresentam resolução espectral muito alta, com precisão em centímetros, enquanto as imagens de satélites gratuitos geralmente têm resolução em metros (PEREIRA et al., 2023). Essa diferença acarreta desafios, como custos elevados, falta de flexibilidade operacional e limitações na resolução espacial (CRUSIOL et al., 2024). As condições climáticas também representam um obstáculo, pois em dias nublados a passagem de luz solar é bloqueada, o que impede a captação de informações sobre a superfície (BEZERRA; SANO; FERREIRA, 2007).

Assim, com a crescente adoção das RPA (aeronaves remotamente pilotadas) no cotidiano, surge um forte potencial para seu uso no manejo florestal, oferecendo vantagens como: custo reduzido em comparação com plataformas orbitais, capacidade para realizar missões específicas, operação em condições adversas e segurança para o piloto (LIMA et al., 2020). Dessa forma, as RPA estão sendo exploradas para a captura de imagens com alta resolução temporal, com possibilidade de aquisição várias vezes ao dia, e espacial, atingindo precisão em centímetros ou até milímetros. Além disso, destaca-se os custos operacionais mais baixos em comparação com aeronaves tripuladas e satélites de alta resolução (PEREIRA et al., 2023). Essas aeronaves são ideais para uso em áreas menores e em locais específicos,

permitindo a coleta de dados em menos tempo e o monitoramento do crescimento de diferentes culturas com rapidez e precisão.

4.6 Satélites Sentinel-1 e Sentinel-2

Os Sentinel-1 e Sentinel-2 são constelações de satélites com aplicações complementares no sensoriamento remoto, que disponibilizam dados gratuitos e abertos ao público pelo programa Copernicus (HADDAD et al., 2022). O Sentinel-1 é uma constelação de satélites de radar de abertura sintética (SAR) desenvolvida pela Agência Espacial Europeia (ESA). Segundo Valdivieso-Ros, Alonso-Sarria e Gomazir-Castillo (2023), o sistema opera em todas as condições meteorológicas e durante o dia e a noite, utilizando radar de banda C (5,405 GHz), o que permite a observação contínua mesmo em regiões com cobertura de nuvens frequente. As imagens do Sentinel-1 são processadas em nível-1, incluindo correções geométricas e radiométricas, e disponibilizadas em formato de amplitude e fase. Esses dados contribuem em aplicações como interferometria SAR (InSAR), que detecta mudanças milimétricas na superfície terrestre, e para o monitoramento de desmatamento (SEGARRA et al., 2020). Para análises de vegetação, o Sentinel-1 destaca-se na detecção de biomassa e estrutura florestal por meio de parâmetros de retro-espalhamento radar, que se correlacionam com a umidade do solo e a densidade de cobertura vegetal (STONE & MOHAMMED, 2017).

Já o Sentinel-2 foi projetado para fornecer dados de alta resolução espacial, espectral e temporal, atendendo às necessidades da silvicultura, agricultura e de pesquisadores acadêmicos (ESA, 2024). Ele utiliza o sensor MSI (MultiSpectral Instrument), que captura dados em 13 bandas espectrais com resoluções espaciais de 10, 20 e 60 metros. Essas características permitem a observação detalhada de fenômenos terrestres, com aplicações em mapeamento de uso e cobertura do solo, análise fenológica e monitoramento ambiental (SEGARRA, 2020). Para plantios florestais o Sentinel-2 também pode ser empregado para gerar mosaicos anuais de imagens, permitindo identificar plantações de eucalipto e analisar ciclos de rotação. Ele se destacou pela capacidade de monitorar plantações de curta rotação, como o *Eucalyptus* spp., graças à sua alta resolução espacial e revisita temporal frequente, o que facilita o planejamento e manejo florestal em escalas regionais e globais (KLINK e MACHADO, 2005).

4.7 Aprendizado de Máquina (Machine learning)

O uso de técnicas de aprendizado de máquina (Machine Learning) tem crescido nos últimos anos na engenharia florestal, principalmente em tarefas como classificação de espécies, previsão de produtividade, detecção de pragas e otimização de recursos (GONZÁLEZ et al., 2021). Entre as técnicas mais empregadas, destacam-se o Random Forest (RF), o Support Vector Machine (SVM) e as Redes Neurais Artificiais. O Random Forest (RF) é um método

baseado em árvores de decisão, introduzido originalmente por Breiman (2001). Essa técnica utiliza múltiplas árvores geradas a partir de amostras aleatórias dos dados e combina suas previsões para melhorar a precisão e reduzir a variância do modelo (BREIMAN, 2001). Na engenharia florestal, o RF tem sido aplicado para estimar parâmetros dendrométricos, classificar tipos de cobertura vegetal e detectar ocorrência de pragas (CAMPOS, 2020). Sua robustez frente a variáveis altamente correlacionadas e sua capacidade de lidar com dados de diferentes escalas tornam o método ideal para cenários complexos em florestas plantadas e nativas brasileiras. O Support Vector Machine (SVM) foi formalizado por Cortes e Vapnik (1995) e baseia-se no conceito de encontrar hiperplanos que maximizem a margem entre classes de dados. Em aplicações de classificação e regressão na engenharia florestal, o SVM se mostra vantajoso em problemas com alta dimensionalidade e com conjuntos de dados relativamente pequenos, pois se vale de núcleos (kernels) para projetar os dados em espaços de maior dimensão (CORTES; VAPNIK, 1995).

Para o manejo de lagartas desfolhadoras, o SVM pode ser empregado na identificação e classificação de imagens de folhas danificadas (CAMPOS, 2020). Ao combinar técnicas de processamento de imagem com algoritmos de aprendizado de máquina, é possível identificar precocemente o início de um surto de lagartas para uma boa tomada de decisão. As Redes Neurais Artificiais (RNA) imitam o funcionamento do cérebro humano por meio de camadas de neurônios artificiais que aprendem a partir de exemplos, ajustando-se de forma iterativa até obter um modelo preditivo satisfatório (HAYKIN, 1999). As RNA podem auxiliar na modelagem de dinâmicas populacionais complexas, levando em conta variáveis como fenologia da planta hospedeira, fatores climáticos e presença de inimigos naturais (SILVA; PEREIRA, 2020).

No que se refere ao manejo de lagartas desfolhadoras, o RF pode ser utilizado para prever surtos populacionais com base em variáveis climáticas (temperatura, umidade) e dados de sensoriamento remoto que indiquem estresse nas plantas (SILVA; PEREIRA, 2020). Dessa forma, os gestores florestais podem adotar medidas preventivas ou corretivas de controle de pragas de maneira mais eficiente.

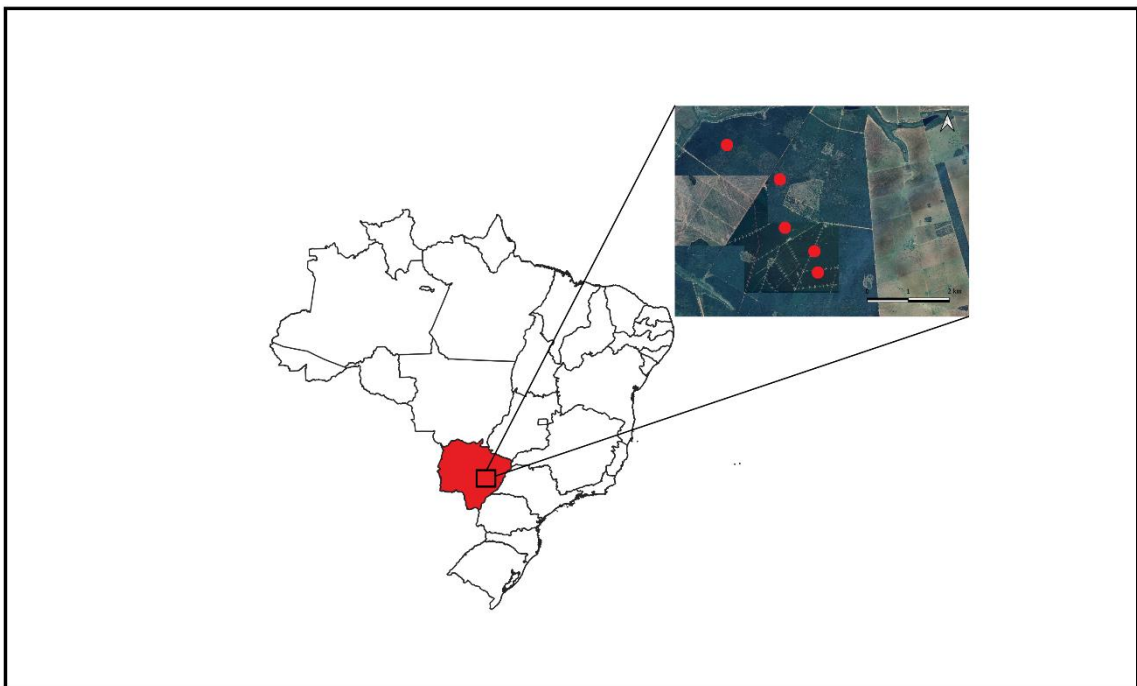
5 MATERIAIS E MÉTODOS

Local de execução do estudo

O estudo foi conduzido em cinco talhões de *Eucalyptus* spp. (híbrido *E. grandis* × *E. urophylla*) localizados na região de Três Lagoas, Mato Grosso do Sul (coordenadas

19°59'36.53"S, 51°58'11.49"O), caracterizada por clima tropical savânico (Aw) e inserida no bioma Cerrado (KLINK e MACHADO, 2005). Os talhões, com idades entre 3 e 6 anos e áreas variando de 20 a 65 hectares, apresentavam espaçamento de 3,5 metros entre linhas e 2,5 metros entre árvores. Os talhões selecionados tinham diferentes níveis de infestação da lagarta desfolhadora *Iridopsis panopla*.

Figura 1. Locais de amostragem de dados na região leste do estado brasileiro de Mato Grosso do Sul (MS). Os pontos vermelhos representam os locais onde foram realizados os tratamentos com diferentes graus de desfolha: 0%, 0 a 25%, 25 a 50%, 50 a 75% e 75 a 100%.



Fonte: Do Autor (2025)

Seleção dos pontos amostrais

Em cada talhão, foram demarcados 30 pontos amostrais para cada tratamento em zigue-zague, espaçados 50 metros entre si e distantes pelo menos 50 metros das bordas, totalizando 150 pontos. As coordenadas geográficas dos pontos foram registradas com um GPS Garmin GPSMap 64s (precisão de 3,6 metros) e logo após convertidas para o formato KML no software TrackMaker, permitindo sua integração ao planejamento autônomo dos voos no software Litchi.

Medição da desfolha

Em cada ponto amostral, quatro árvores agrupadas foram avaliadas manualmente, seguindo o protocolo de amostragem visual empregado pela equipe técnica da empresa florestal e baseado nos princípios de Manejo Integrado de Pragas (MIP). O técnico responsável, juntamente com o pesquisador, atribuiu a cada árvore uma estimativa percentual de desfolha (0 % a > 75 %) por inspeção direta da copa. Em seguida, calculou-se a média dessas quatro estimativas para o ponto, classificando-o em cinco tratamentos: tratamento 1 (0 % de desfolha – testemunha), tratamento 2 (1–25 %), tratamento 3 (26–50 %), tratamento 4 (51–75 %) e tratamento 5 (> 75 %). Esse procedimento garantiu padronização na coleta, reduzindo variações de julgamento entre avaliadores e assegurando que os dados refletissem fielmente a condição real do dossel.


Coleta de fotografias hemisféricas

Simultaneamente, no centro de cada ponto, entre as quatro árvores avaliadas, foram realizadas fotografias hemisféricas do dossel utilizando uma lente olho de peixe voltada para o zênite. As fotos foram registradas entre 9h e 12h. As imagens obtidas foram posteriormente analisadas no software GLA (Gap Light Analyzer), permitindo quantificar tanto a abertura do dossel quanto o índice de área foliar, de modo a embasar a avaliação dos diferentes níveis de desfolha.

Coleta de imagens RGB com drone

A coleta de imagens aérea em cada ponto amostral foi realizada com o drone DJI Phantom 4, equipado com uma câmera RGB de 12,4 megapixels sensor CMOS de 1/2,3" e lente de campo de visão (FOV) de 94° (Figura 1). Os voos foram realizados entre 9h e 12h. Para a programação do voo, foi utilizado o software Litchi, devido à sua excelente capacidade de automação de rotas e compatibilidade com dispositivos DJI. O processo iniciou-se com a preparação dos pontos amostrais no software TrackMaker, onde as coordenadas georreferenciadas dos 150 pontos (30 por talhão), coletadas com GPS Garmin GPSMap 64s (precisão de 3,6 m), foram exportadas em formato KML (Keyhole Markup Language). Esse arquivo, ajustado para projeção UTM (Zona 22S, WGS84), garantiu a compatibilidade com o Litchi, evitando inconsistências na importação.

Figura 2. Equipamentos de voo. **A:** Controle de voo. **B:** RPAS DJI. **C:** Controle. **D:** Câmera RGB



Fonte: Do Autor (2025)

No Litchi, os pontos foram carregados como waypoints (coleta de imagens em pontos de interesse), definindo uma rota autônoma com parâmetros operacionais padronizados: altitude de 120 m (para resolução espacial de ~ 3 cm/pixel), velocidade de 6,4 m/s, sobreposição frontal e lateral de 80% e 70%, respectivamente, e ângulo do gimbal fixo em -90° , assegurando orientação perpendicular da câmera ao solo. Para otimizar a qualidade das imagens, comandos específicos foram programados em cada waypoint. Ao atingir um ponto, o drone executava a sequência: (1) estabilização por 2 segundos, (2) captura da primeira foto, (3) espera de 5 segundos para redução de vibrações residuais, (4) disparo de uma segunda foto e (5) rotação de 40° no eixo vertical (yaw), permitindo a aquisição de múltiplos ângulos do dossel para análises tridimensionais. As curvas entre pontos foram configuradas como "suaves" (raio de 14 m), minimizando oscilações durante o deslocamento.

A eficácia dessa abordagem é respaldada por estudos como o de Silva et al. (2022), que destacam a importância de intervalos entre disparos para reduzir borramento, e Lee e Tanaka (2021), que validaram rotações programadas entre 30° e 45° para modelagem 3D precisa em florestas.

O fluxo operacional integrou coleta de coordenadas, conversão no TrackMaker, programação de comandos no Litchi e execução autônoma, assegurando padronização e replicabilidade. Essa metodologia, alinhada a práticas reconhecidas em sensoriamento remoto, reforça a confiabilidade dos dados obtidos para avaliação de desfolha em talhões de eucalipto. (Tabela 1).

Tabela 1. Parâmetros de voo com o drone

Parâmetros dos Voos com Drone	Valores
Altitude de voo (m)	120
Velocidade (m/s)	6,4
Sobreposição Frontal (%)	80
Sobreposição Lateral (%)	70
Resolução Espacial (cm/pixel)	~3 cm/pixel
Ângulo do Gimbal	-90°
Número de Pontos Amostrais	150
Software de Planejamento	Litchi

Fonte: Do autor (2025).

Processamento das imagens do drone

O processamento digital das imagens RGB capturadas pelo drone foi conduzido no ambiente de programação R (versão 4.5.6), com recorte localizado em buffers de 30 metros ao redor dos pontos e utilizando pacotes especializados em análise geoespacial.

As imagens multiespectrais foram importadas como RGB e definição do sistema de referência de coordenadas UTM (Zona 22S, datum WGS84). Para equalização radiométrica, aplicou-se uma normalização linear aos valores de reflectância (HUANG et al., 2015), conforme a equação:

$$v(normalized) = \frac{255}{\max(v) - \min(v)} \times (v - \min(v))$$

Onde v representa os valores de pixel originais. Essa etapa visa reduzir variações de iluminação e melhorar a homogeneidade espectral (JENSEN, 2015).

O Índice de Percentagem de Verde (G%) foi empregado para segmentação da cobertura vegetal, seguindo a fórmula adaptada de estudos de sensoriamento remoto (GITELSON et al., 2002):

$$G\%(normalized) = \frac{Banda\ verde}{Banda\ Vermelha + Banda\ Verde + Banda\ Azul} \times 100$$

Esse índice destaca a contribuição espectral da clorofila, permitindo a discriminação entre vegetação saudável e áreas desfolhadas.

A classificação binária (vegetação vs. não vegetação) foi realizada com o algoritmo Huang2, implementado no pacote *autothresholdr* (HIJMANS, 2023). O limiar ótimo (T) foi determinado automaticamente, baseando-se na distribuição dos valores de G% (HUANG e WANG, 1995). Pixels com valores superiores a T foram classificados como vegetação (valor 1), e os demais como não vegetação (valor 0).

As máscaras binárias resultantes foram exportadas em formato GeoTIFF, garantindo compatibilidade com sistemas de informação geográfica (SIG). A consistência geométrica foi validada mediante sobreposição das coordenadas dos pontos amostrais coletados em campo.

Coleta e processamento das imagens do Sentinel 1 e 2

Para complementar a análise da desfolha em *Eucalyptus spp.*, foram integradas imagens dos satélites Sentinel-1 (radar de abertura sintética - SAR) e Sentinel-2 (imagens ópticas multiespectrais), adquiridas próxima a datadas coletas de campo e de drone.

As imagens SAR do Sentinel-1, adquiridas no modo de sensor Interferometric Wide Swath (IW), foram processadas no Google Earth Engine (GEE). Inicialmente, foram extraídas as polarizações HH (Horizontal-Horizontal) e HV (Horizontal-Vertical), e depois calculados os índices Radar Vegetation Fraction Index (RVFI), Radar Forest Degradation Index (RFDI) e Radar Ratio Index (RATIO), que estão relacionados às propriedades do radar e à caracterização da vegetação.

O download das imagens foi realizado a partir da coleção Sentinel-1 GRD (Ground Range Detected), disponível no GEE. O pré-processamento incluiu a aplicação de correção radiométrica, filtragem speckle e reprojeção para um sistema de referência geográfico adequado à análise.

Já as imagens do Sentinel-2 foram processadas exclusivamente no Google Earth Engine (GEE), sem o uso do R. Inicialmente, foram extraídas as bandas espectrais B2 (azul), B3 (verde), B4 (vermelho) e B8 (infravermelho próximo - NIR), provenientes do produto MSI Level-2A, que fornece imagens corrigidas atmosféricamente. A partir dessas bandas, foram calculados os índices de vegetação NDVI (Normalized Difference Vegetation Index), GNDVI (Green Normalized Difference Vegetation Index), TVI (Transformed Vegetation Index) e SIPI (Structure-Insensitive Pigment Index), fundamentais para a correlação com os níveis de desfolha.

As imagens SAR e ópticas foram espacialmente alinhadas às imagens de drone utilizando regressores de correção polinomial no QGIS. As variáveis extraídas (RVFI, RATIO, RFDI do Sentinel-1 e NDVI, GNDVI, TVI, SIPI do Sentinel-2) foram combinadas e submetidas a modelos de aprendizado de máquina. A integração dos dados SAR (relacionados à estrutura do dossel) e ópticos (relacionados à saúde foliar) aprimorou a detecção de gradientes de desfolha, conforme observado em estudos similares (JOSHI et al., 2016). (Tabela 2)

Tabela 2. Dados comparativos Sentinel-1 e Sentinel-2.

Parâmetro	Sentinel-1 (SAR)	Sentinel-2 (Óptico)
Sensor	SAR	MSI
Bandas espectrais	Banda C (5,405 GHz)	13 bandas (B2 a B12)
Resolução Espacial	Modo IW	B2-B4, B5-B7, B8A, B11-B12), B1, B9, B10
Resolução temporal	6 dias	5 dias
Polarizações	VV, VH	Não aplicável
Principais índices utilizados	RATIO, RVFI, RFDI	NDVI, GNDVI, SIPI, TVI
Correções aplicadas	Speckle filtering, reprojeção	Correção atmosférica, normalização

Fonte: Do Autor (2025)

Análise estatística

A suficiência do intervalo de cobertura do dossel (cc) de 0 a 100% foi avaliada por meio da distribuição de frequência em um histograma. As bandas do Sentinel-1 e os índices e bandas do Sentinel-2 foram submetidos a um processo de seleção de variáveis para eliminar redundâncias e colinearidade, utilizando o método Spearman com um limite de correlação de 0,90, garantindo a escolha das melhores variáveis preditoras da cobertura do dossel (cc).

A modelagem computacional da cobertura vegetal (cc) em função das melhores variáveis satelitais foi realizada utilizando o modelo de Random Forest (RF) (Breiman, 2001). O número de variáveis utilizadas na geração de cada árvore (mtry), além do número de árvores (ntree) foi de 1, 2 e 3, variando de 50, 100, 250, 500, 750 e 1000 árvores de decisão, foram os principais grupos de parâmetros deste modelo, determinados durante o ajuste (Breiman, 2001). Após a abordagem RF, a Máquina de Vetores de Suporte (Support Vector Machine - SVM) também foi testada, utilizando as seguintes abordagens linear, polinomial e radial.

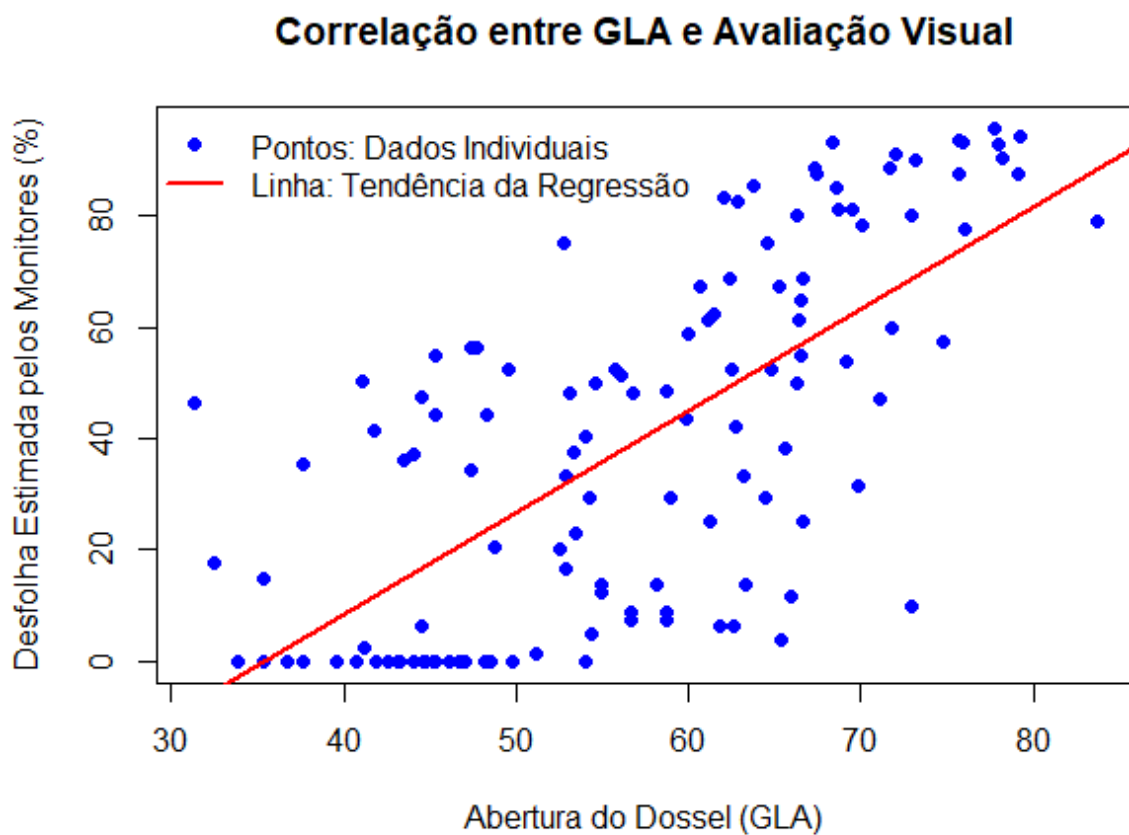
A abordagem de rede neural (RN) foi a última testada, como uma técnica de aprendizado profundo (deep learning), consistindo na geração de uma RN para modelar a cobertura vegetal. Foram utilizadas arquiteturas de RN com diferentes profundidades de rede (32, 64 e 128 camadas), dropout (50%), regularização (0,001) em 50, 100 e 250 épocas e função de ativação ReLU (Rectified Linear Unit) e saída sigmoideal (Alizadeh e Fazel, 2017). O desempenho de cada modelo foi comparado ao final por meio do erro médio absoluto (MAE) e da análise de médias utilizando o teste de ordenação pairwise.t.test com correção de Bonferroni.

6 RESULTADOS E DISCUSSÃO

Relação entre avaliação visual e fotográfica hemisférica na estimativa da desfolha

Foram utilizadas a correlação de Spearman e o gráfico de Bland-Altman, permitindo verificar a consistência entre os métodos e identificar possíveis discrepâncias. A correlação de Spearman revelou uma relação positiva e significativa entre a porcentagem de desfolha estimada pelos monitores e a abertura do dossel estimada pela fotografia hemisférica (GLA) ($\rho = 0.7119$, $p < 2.2 \times 10^{-16}$). O gráfico de dispersão (Figura 2) reforça essa relação, mostrando uma tendência crescente nos dados ao longo da linha de regressão. Esses resultados sugerem que as fotografias hemisféricas são uma ferramenta confiável para o monitoramento da desfolha, podendo substituir a avaliação visual realizada no campo por monitores.

Figura 3. Gráfico de correlação entre a porcentagem de desfolha estimada visualmente por monitores de campo e abertura do dossel (GLA) estimada por fotografia hemisférica da copa de eucalipto infestado por lagartas desfolhadoras.




Fonte: Do autor (2025)

A sensibilidade do GLA também foi observada nas pesquisas de Jin et al. (2024) e Jarčuška et al. (2010), nas quais os autores utilizaram essa ferramenta para a estimativa quantitativa da estrutura do dossel e seus impactos no ambiente florestal. Os estudos apontaram diferenças significativas entre diferentes tipos de floresta, comprovando a sua eficácia em capturar variações estruturais na vegetação.

Todavia, o gráfico evidencia a dispersão dos pontos, indicando variações na estimativa da desfolha entre os métodos. Essa variação pode estar associada à subjetividade da avaliação visual, pois o julgamento humano pode levar à superestimação ou subestimação da cobertura do dossel. Esse aspecto também é discutido por Barros, Loiola e Viani (2023), que apontam que, apesar de mais objetivo, o GLA pode apresentar diferenças sistemáticas devido ao limiar de segmentação das imagens hemisféricas, influenciando a distinção entre o dossel e as áreas abertas. Além disso, o software tende a superestimar ou subestimar a desfolha em situações extremas, como 0% e entre 75% e 100% de desfolha (Figura 3), apresentado nesse presente estudo, evidenciando a necessidade de ajustes metodológicos para maior precisão.

Figura 4. Foto hemisférica do dossel de eucalipto com (A) 0% de desfolha e (B) entre 75 a 100% de desfolha por lagarta desfolhadora.

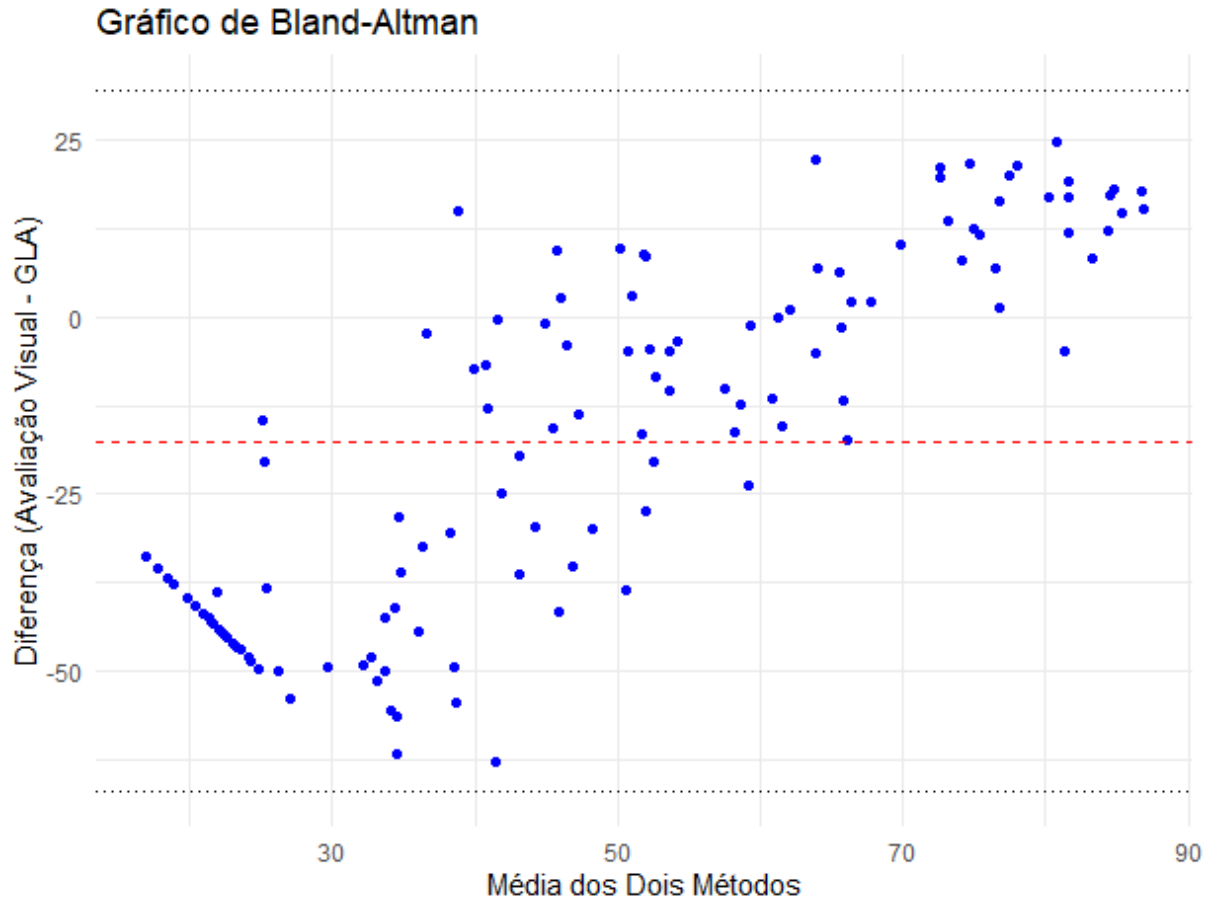


Fonte: Do Autor (2025)

A análise do Gráfico de Bland-Altman (Figura 4) reforça essa variação ao demonstrar a diferença entre os dois métodos em função de sua média. A dispersão dos pontos ao longo do eixo vertical indica a magnitude das diferenças sistemáticas entre a avaliação visual e o GLA. Essa diferença pode ser explicada pelo fato de que, enquanto a avaliação visual considera diretamente o dano visível nas folhas, o GLA mede a quantidade de luz que atravessa o dossel.

Esse fator pode ser influenciado não apenas pela presença ou ausência de folhas, mas pela estrutura da copa e pela distribuição das lacunas no dossel.

Figura 5. Gráfico de Bland-Altman



Fonte: Do Autor (2025)

A dispersão apontada na figura 4 dos pontos ao longo do eixo vertical indica a magnitude das diferenças sistemáticas entre a avaliação visual e o GLA. A análise visual do gráfico também sugere que as discrepâncias são mais pronunciadas em níveis extremos de desfolha, em que a diferença entre os métodos se torna mais evidente. Em níveis baixos ou intermediários, pode-se observar uma tendência de menor dispersão, indicando que a relação entre os métodos se mantém mais estável.

O eixo X representa a média entre a desfolha estimada visualmente e a abertura do dossel medida pelo GLA, enquanto o eixo Y indica a diferença entre os dois métodos. Observa-se que, para médias de desfolha acima de 50%, o GLA tende a subestimar a abertura do dossel em relação à avaliação visual, indicando que, mesmo com perdas foliares elevadas, a estrutura da copa ainda reduz a incidência de luz direta. Por outro lado, para médias de desfolha entre

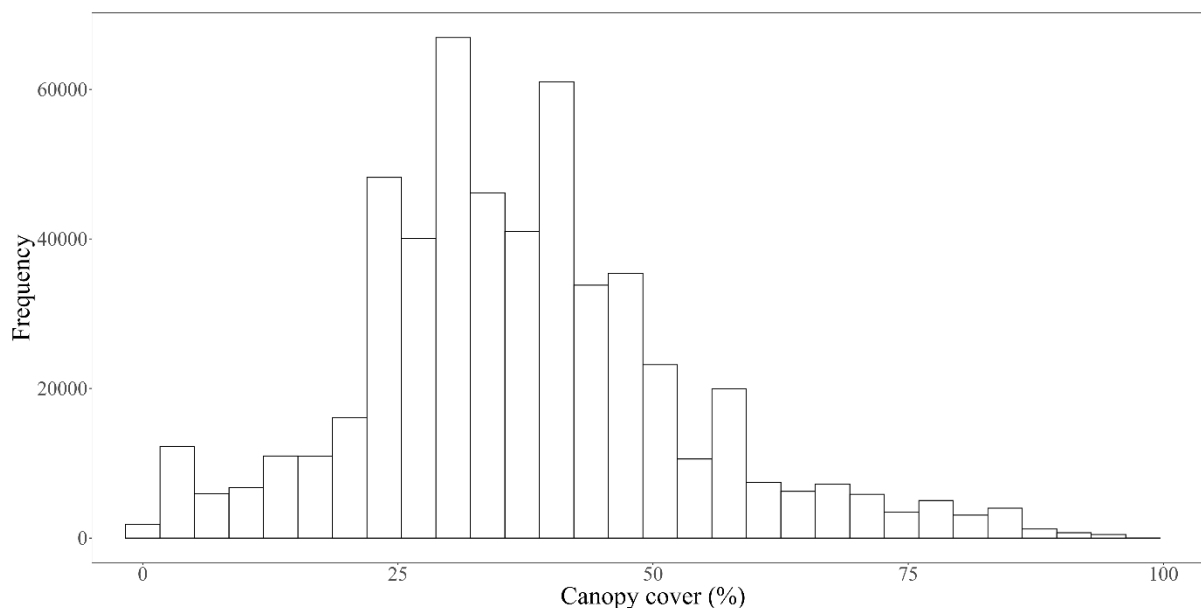
0% e 30%, o GLA superestima a abertura do dossel, possivelmente porque pequenas perdas foliares já são consideradas na análise de desfolha. A aplicação desse modelo de gráfico complementa a análise de teste de correlação, ao fornecer uma representação visual clara da distribuição das diferenças entre os métodos. Giavarina (2015) destaca que esse tipo de abordagem é útil quando se deseja substituir ou complementar um método tradicional no campo por outra forma mais atual, o que reforça sua pertinência no presente estudo.

Estimativa da desfolha utilizando Sentinel-1 e Sentinel-2 e aprendizado de máquina

A integração das imagens de drone, segmentadas pelo índice de Percentagem de Verde (G%) e classificadas em vegetação vs. não vegetação, serviu como “verdade de campo” de alta resolução para validar e ajustar as estimativas de desfolha derivadas dos sensores de satélite. A correlação espacial dessas imagens com as cenas do Sentinel-1 (SAR) e Sentinel-2 (ópticas) evidenciou alta aderência (Spearman $> 0,70$) entre a classificação binária e os índices RATIO, RVFI, RFDI, NDVI, GNDVI, SIPI e TVI, principalmente na faixa de 20% a 50% de desfolha. Um estudo que corrobora a eficácia da integração de dados de drones com imagens dos satélites Sentinel-1 e Sentinel-2 é o de Navarro et al. (2019). O trabalho demonstrou que a integração dessas fontes melhora a predição de biomassa, com altos coeficientes de correlação entre os índices espectrais derivados do Sentinel-2 e os valores obtidos a partir das imagens de UAV.

Nos extremos (próximos a 0% e 100%), notaram-se maiores discrepâncias, possivelmente devido à dificuldade dos sensores em caracterizar copas muito fechadas ou altamente abertas. Ainda assim, a distribuição da cobertura do dossel (cc) contemplou todas as classes de desfolha, com predominância entre 20% e 50%, assegurando a suficiência de dados para ajustar os modelos (Figura 6). Esse comportamento também foi notado em estudos de detecção de desfolha, pois os sensores podem superestimar a densidade foliar em situações de copas fechadas ou subestimar quando há lacunas e clareiras na vegetação (GIAVARINA, 2015). Mesmo assim, a distribuição equilibrada dos valores de cobertura (cc) na faixa intermediária favoreceu o ajuste dos modelos de aprendizado de máquina, confirmando a utilidade de uma amostra abrangente para capturar nuances de diferentes níveis de desfolha.


Figura 6. Histograma da distribuição da cobertura do dossel (CC) de eucalipto infestado com lagartas desfolhadoras, variando de 0 a 100%, utilizado para avaliar a suficiência do intervalo de dados.



As variáveis selecionadas pelo método Spearman com um limite de correlação de 0,90 foram VV, VH, RATIO, B2, B3, B4, B8, GNDVI, PRI e SIPI, representando as bandas do Sentinel-1 e Sentinel-2, além dos índices espectrais mais relevantes para a predição da cobertura do dossel (cc). Os menores valores de MAE indicam melhor desempenho, pois representam menor erro na predição da cobertura do dossel. Os melhores resultados foram obtidos pelos modelos SVM e RF, que apresentam os menores valores de erro. Em particular, os modelos SVM radial, SVM polinomial e SVM linear, bem como algumas configurações de RF (Random Forest), exibem os menores valores de MAE, indicando maior precisão na modelagem (Tabela 3). Esse achado é coerente com os resultados obtidos por LIN et al. (2023), que desenvolveram um método para extração de áreas de plantação de eucalipto com base na seleção de características utilizando SLPSO–RFE e na classificação com RF e SVM. No estudo comparado, a combinação de dados multitemporais dos satélites Sentinel-1 e Sentinel-2 com um método avançado de seleção de características resultou em um aumento significativo na acurácia da classificação, atingindo 97,97% de acurácia com RF, 96% com CART e 95,48% com SVM (LIN et al., 2023). Assim, os modelos SVM e RF demonstraram maior precisão, confirmando a robustez dessas abordagens para a modelagem da vegetação.

Por outro lado, as Redes Neurais (NN) apresentam os maiores valores de MAE, indicando um desempenho inferior em relação às outras abordagens. Isso sugere que os modelos baseados em redes neurais tiveram maior dificuldade na predição da cobertura do dossel, possivelmente devido à complexidade dos dados ou à necessidade de ajustes mais refinados nos hiperparâmetros da rede (Figura 7).

Figura 7. Comparação do desempenho dos modelos por meio do erro médio absoluto (MAE), utilizando o teste de ordenação pairwise.t.test com correção de Bonferroni para avaliar diferenças estatísticas entre as médias.



A análise dos resultados obtidos na predição da cobertura do dossel (cc) evidencia um desempenho superior dos modelos Support Vector Machine (SVM) e Random Forest (RF) em relação às Redes Neurais Artificiais (ANN). Este achado está em consonância com estudos anteriores que avaliaram a eficácia desses algoritmos em contextos similares.

Na pesquisa conduzida por Holanda (2021), que avaliou o desempenho dos algoritmos RF, Decision Tree (DT) e SVM na classificação de imagens de satélite no bioma Cerrado, o RF apresentou desempenho superior, seguido pelo SVM. Este resultado corrobora a eficácia desses algoritmos em tarefas de classificação de dados de sensoriamento remoto.

Adicionalmente, Narvaes et al. (2024) investigaram a distinção de espécies florestais utilizando RF, SVM e ANN. Os resultados indicaram que o ANN obteve os melhores resultados, seguido pelo SVM e RF, com acurácias globais de 98,9%, 94,44% e 93,33%, respectivamente. Embora o ANN tenha apresentado desempenho superior neste caso, é importante notar que a eficácia dos algoritmos pode variar dependendo do contexto e dos dados utilizados.

No presente estudo, as ANN apresentaram os maiores valores de MAE, indicando um desempenho inferior na predição da cobertura do dossel. Este resultado pode ser atribuído a diversos fatores, incluindo a complexidade dos dados, a necessidade de ajustes mais refinados nos hiperparâmetros da rede e a sensibilidade das ANN a ruídos nos dados.

Pesquisas anteriores também relataram desempenho abaixo do esperado das ANN em determinadas aplicações. Por exemplo, Araujo (2022) avaliou o uso de aprendizado de máquina para modelagem de crescimento e produção em plantações de eucalipto e observou que, embora as ANN tenham potencial, seu desempenho pode ser limitado por fatores como a complexidade dos dados e a necessidade de parametrização adequada.

7 CONCLUSÃO

Os resultados evidenciaram que a fotografia hemisférica pode substituir a avaliação visual em campo, reduzindo a subjetividade da estimativa de desfolha usada para a tomada de decisão de controle de lagartas desfolhadoras. Os algoritmos SVM e Random Forest apresentaram menores erros de predição da desfolha por lagartas, enquanto as Redes Neurais exibiram desempenho inferior. A aplicação conjunta de métodos estatísticos (para avaliar a concordância) e modelos de aprendizado de máquina (para predição) permite uma compreensão mais abrangente das lacunas e potencialidades na estimativa de desfolha do dossel. –

REFERÊNCIAS

- ABD EL-GHANY, N. M.; ABD EL-AZIZ, S. E.; MAREI, S. S. **A review: application of remote sensing as a promising strategy for insect pests and diseases management.** Environmental Science and Pollution Research, v. 27, n. 27, p. 33503–33515, 2020.
- ANJOS, N.; G.P. SANTOS; ZANUNCIO, J.C. **Pragas do eucalipto e seu controle.** Informativo Agropecuário. 50-8p, 1996.
- ASSIS, Gabriel Moura de; MAYCON, Nathan Fidelis; PEREIRA, Flávio Ferraz. **Manejo de formigas cortadeiras no cultivo do eucalipto.** In: SEBBENN, Alexandre Magno;

MORAES, Mauricio Luiz Teixeira de. (Org.). Eucalipto: produção, manejo e conservação genética. Colombo: Embrapa Florestas, 2021.

BARROS, A. J.; LOIOLA, P. P. P.; VIANI, R. A. G. **Chemical thinning and fisheye clip for managing light intensity in the understory of forest restoration**. *Forests*, v. 14, n. 11, p. 2140, 2023

BEZERRA, H.S.; SANO E.E.; FERREIRA, L.G. **Desempenho do satélite sino-brasileiro de recursos terrestres CBERS-2 no mapeamento da cobertura da terra no Distrito Federal, Brasil**. *Revista Brasileira de Geofísica*, n. 25, v. 2, p. 171 - 185, 2007.

BREHM, G.; MURILLO-RAMOS, L.; SIHVONEN, P.; HAUSMANN, A.; SCHMIDT, B. C.; ÖUNAP, E.; MOSER, A.; MORTTER, R.; BOLT, D.; BODNER, F.; LINDT, A.; PARRA, L. E.; WAHLBERG, N. **New World geometrid moths (*Lepidoptera: Geometridae*): molecular phylogeny, biogeography, taxonomic updates and description of 11 new tribes**. *Arthropod Systematics & Phylogeny*, v. 77, p. 457, 2019.

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

CAMPOS, F. S. **Monitoramento remoto de pragas em florestas plantadas por meio de técnicas de aprendizado de máquina**. *Floresta e Ambiente*, v. 27, e20180123, 2020.

CORTES, C.; VAPNIK, V. **Support-vector networks**. *Machine Learning*, v. 20, n. 3, p. 273-297, 1995.

CLARO FILHO, Sérgio Fernandes; CONCEIÇÃO, Thiago Silva da; RIBEIRO FILHO, José Roberto. **O sensoriamento remoto no ensino básico: a comunicação universidade-escola quanto à produção, divulgação e uso de material didático**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis.

CRUSIOL, L. G. T.; SIBALDELLI, R. N. R.; NANNI, M. R.; FRANCHINI, J. C.; FARIAS, J. R. B. **Conceitos e definições de sensoriamento remoto para monitoramento da soja**. Londrina: Embrapa Soja, 2024.

DA SILVA BARROS, Pedro Paulo et al. Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Rev. Bras. Cartogr**, v. 73, n. 2, 2021.

DOMINGOS JÚNIOR, Fausto Antônio et al. **Identificação aprimorada de seringais infestados por fitonematoides no município de Prata, MG, por sensoriamento remoto**. 2020. SILVA, R. M. et al. Monitoramento de lagartas desfolhadoras em eucalipto: métodos de avaliação e níveis de controle. *Revista de Entomologia Aplicada*, v. 12, n. 1, p. 54-62, 2017.

FRAZER, G. W.; CANHAM, C. D.; LERTZMAN, K. P. **Gap Light Analyzer (GLA), Version 2.0: Imaging software to extract canopy structure and gap light transmission indices from true-colour fisheye photographs**. *Bulletin of the Ecological Society of America*, v. 80, n. 3, p. 191-197, 1999.

GALLO, Domingos et al. **Entomologia Agrícola. Piracicaba: FEALQ, 2002**. (Biblioteca de Ciências Agrárias Luiz de Queiroz, v. 10).

- GONZÁLEZ, A. B.; SOUZA, M. A. A.; SILVA, R. A. **Use of machine learning in forest engineering: a review of current applications and future trends.** *Journal of Forestry*, v. 120, n. 5, p. 555-560, 2021.
- GITELSON, A. A. et al. **Novel algorithms for remote estimation of vegetation fraction.** *Remote Sensing of Environment*, v. 80, n. 1, p. 76-87, 2002. HIJMANS, R. J. Package 'terra'. 2023.
- HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; DALAGNOL, R.; BOURScheidt, V.; JACON, A. D. **On the combined use of phenological metrics derived from different PlanetScope vegetation indices for classifying savannas in Brazil.** *Remote Sensing Applications: Society and Environment*, v. 26, 2022.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. New Jersey: Prentice Hall, 1999.
- HALL, R. J. et al. **Remote sensing of forest pest damage: a review and lessons learned from a Canadian perspective.** *Forest Ecology and Management*, v. i, n. 2016.
- HURLEY, A. et al. **Identifying gypsy moth defoliation in Ohio using Landsat data.** *Environmental and Engineering Geoscience*, v. 10, n. 4, p. 321–328, 2004.
- IBÁ. Brazilian tree industry annual report - base year 2019. *Associação Brasileira de Árvores*, p. 160, 2020.
- JAROLMASJED, S.; SANKARAN, S.; MARZOUGUI, A.; KOSTICK, S.; SI, Y.; VARGAS, J. J. Q.; EVANS, K. **High-throughput phenotyping of fire blight disease symptoms using sensing techniques in apple.** *Frontiers in Plant Science*, Lausanne, v. 10, n. May, p. 576, 2019.
- JARČUŠKA, B.; KUCBEL, S.; JALOVÍAR, P. **Comparison of output results from two programmes for hemispherical image analysis: Gap Light Analyser and WinScanopy.** *Journal of Forest Science*, v. 56, n. 4, p. 147-153, 2010.
- JOHANSEN, K. et al. **Using GeoEye-1 imagery for multi-temporal object-based detection of canegrub damage in sugarcane fields in Queensland, Australia.** *GIScience and Remote Sensing*, v. 55, n. 2, p. 285–305, 2018.
- KUMBULA, S. T.; MAFONGOYA, P.; PEERBHAY, K. Y.; LOTTERING, R. T.; ISMAIL, R. **Using Sentinel-2 multispectral images to map the occurrence of the Cossid moth (*Coryphodema tristis*) in *Eucalyptus nitens* plantations of Mpumalanga, South Africa.** *Remote Sensing*, Madison, v. 11, n. 3, p. 278, 2019.
- LEMES, Pedro Guilherme; ZANUNCIO, José Cola (Org.). **Novo Manual de Pragas Florestais Brasileiras.** Montes Claros: Instituto de Ciências Agrárias da Universidade Federal de Minas Gerais, 2021.
- LIMA, Renata Barbosa et al. **Manejo Florestal 4.0: Passos para Emprego de Aeronaves Remotamente Pilotadas (Drones) no Planejamento Florestal em Nativas.** Colombo: Embrapa Florestas, 2020.

MARTÍNEZ PRENTICE, R.; VILLOSLADA, M.; WARD, R. D.; KULL, A.; KULL, T.; PAAL, T. **Synergistic use of Sentinel-2 and UAV-derived data for plant community cover mapping in coastal meadows**. *Biogeosciences*, v. 21, p. 1411–1431, 2024.

MILHOMEM, Sara Bezerra Bandeira; SANTOS, Lorena Paulina dos; SILVA, Jonatas Carlos da; FERREIRA, Rinaldo Luiz Caraciolo; SILVA, José Antônio Aleixo da; HAKAMADA, Rodrigo Eiji. **Biomassa, uniformidade e sobrevivência inicial de eucalipto sob diferentes sistemas silviculturais e condições edafoclimáticas**. *Série Técnica IPEF*, v. 26, n. 48, p. 352-355, 2023.

MONTAGNER, C. C. et al. **Modelagem de surtos de lagartas desfolhadoras em plantios de eucalipto utilizando redes neurais artificiais**. *Ciência Florestal*, v. 29, n. 2, p. 591-602, 2019.

MUTANGA, O.; DUBE, T.; GALAL, O. **Remote sensing of crop health for food security in Africa: Potentials and constraints**. *Remote Sensing Applications: Society and Environment, Amsterdam*, v. 8, p. 231- 239, 2017.

NAVARRO, J. A.; ALGEET, N.; FERNÁNDEZ-LANDA, A.; ESTEBAN, J.; RODRÍGUEZ-NORIEGA, P.; GUILLÉN-CLIMENT, M. L. **Integration of UAV, Sentinel-1, and Sentinel-2 Data for Mangrove Plantation Aboveground Biomass Monitoring in Senegal**. *Remote Sensing*, v. 11, n. 1, p. 77, 2019.

OLIVEIRA, Fabiana Lopes Ramos de; CABACINHA, Christian Dias; SANTOS, Leonardo David Tuffi. **Crescimento inicial de eucalipto e acácia em diferentes arranjos de integração lavoura-pecuária-floresta**. *Cerne*, v. 21, n. 2, p. 227-233, 2015.

PARANHOS FILHO, A. C.; MIOTO, C. L.; PESSI, D. D. **Introdução a Conceitos de Sensoriamento Remoto**. Campo Grande: Editora UFMS, 2021.

PEREIRA, Paulo Roberto Mendes; OLIVEIRA, Mariana Monteiro Navarro de; BOLFE, Edson Luis; MACARRINGUE, Lucrêncio Silvestre. **Comparação da classificação do uso e cobertura da terra em imagens Landsat-8 e Sentinel-2 no Cerrado Maranhense**. *Geo UERJ*, n. 42, e66306, 2023.

PEREIRA, Raquel Susana da Costa; SILVA JUNIOR, Raimundo Gomes da. **Análise da Competitividade no Setor da Celulose: O Caso do Brasil no Período 2008-2017**.

PITKIN, L. M. **Neotropical ennomine moths: a review of the genera (Lepidoptera: Geometridae)**. *Zoological Journal*, v. 135, p. 121-401, 2002.

PONZONI, Flávio Jorge. **Avaliação de imagens-índice e imagens-proporção na identificação de plantios florestais desfolhados por geadas e pelo ataque de insetos**. *Scientia Forestalis*, n. 54, p. 107-118, 1998.

RULLAN-SILVA, C. D. et al. **Remote monitoring of forest insect defoliation: A review**. *Forest Systems*, v. 22, n. 3, p. 377–391, 2013.

Fronteiras: Journal of Social, Technological and Environmental Science, v. 13, n. 1, p. 150-166, 2024.

RODRIGUES, Gelze Serrat S. C.; OLIVEIRA, Marcus Vinícius N. de; SILVA, Maria das Graças. **Eucalipto no Brasil**. Edição revisada. Uberlândia: EDUFU, 2024.

SANTOS, F. A.; WILCKEN, C. F.; NANINI, F.; CORREA, A. S.; GIANEZZI, L. V. B.; PEREIRA, F. F. ***Iridopsis panopla* (Lepidoptera: Geometridae): uma nova lagarta desfolhadora de Eucalyptus no Brasil**. In: ENCONTRO DE ENTOMOLOGIA E CONSERVAÇÃO DA BIODIVERSIDADE, 2., 2021, Dourados. Anais [...]. Dourados: Universidade Federal da Grande Dourados, 2021.

SANTOS, P. E. T.; GERALDI, I. O.; GARCIA, J. N. **Estimates of genetic parameters of wood traits for sawn timber production in *Eucalyptus grandis***. *Genetics and Molecular Biology*, v.27, n.4, p.567-573, 2004.

SANTOS, Thamires Lima dos. **Análise faunística de lepidópteros-praga em plantios de eucalipto no Brasil**. 2023.

SOUSA, João Marcos Rebessi. **Modelagem da biomassa de plantações florestais a partir da tecnologia LiDAR embarcada em drone**. 2023.

SILVA, R. F.; PEREIRA, A. A. M. **O manejo integrado de lagartas desfolhadoras em plantios florestais**. *Revista de Entomologia Florestal*, v. 33, n. 4, p. 45-52, 2020.

SOLIMAN, E. P. **Sanidade Florestal e a busca pela sustentabilidade da produção**. VIII Simpósio Sobre Técnicas de Plantio e Manejo de Eucalipto para Uso Múltiplos Piracicaba. 2014.

STONE, C.; MOHAMMED, C. Application of remote sensing technologies for assessing planted forests damaged by insect pests and fungal pathogens: a review. *Current Forestry Reports*, v. 3, n. 2, p. 75–92, 2017.

SILVA, Rafael Navas; NASCIMENTO, Marli Reis. A certificação florestal do eucalipto na responsabilidade social: Um estudo de caso no Sudoeste Paulista. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 8, n. 4, p. 23, 2013.

SEGARRA, J.; BUCHAILLOT, M. L.; ARAUS, J. L.; KEFAUVER, S. C. **Remote sensing for precision agriculture: Sentinel-2 improved features and applications**. *Agronomy*, v. 10, n. 5, p. 641, 2020.

SOLIMAN, E. P. **Sanidade Florestal e a busca pela sustentabilidade da produção**. VIII Simpósio Sobre Técnicas de Plantio e Manejo de Eucalipto para Uso Múltiplos Piracicaba. 2014.

SPRACKLEN, Ben; SPRACKLEN, Dominick V. **Synergistic use of Sentinel-1 and Sentinel-2 to map natural forest and acacia plantation and stand ages in North-Central Vietnam**. *Remote Sensing*, v. 13, n. 2, p. 185, 2021.

THOMPSON, L. J.; SHI, Y.; FERGUSON, R. B. **Getting Started with drones in Agriculture**. Lincoln: University of Nebraska, Extension, 2017.

VERA, Damaris Elias; LAURA, Valdemir Antônio; FERREIRA, André Dominghetti; COUTO, Allan Motta. **Crescimento e forma do eucalipto em função da densidade de plantio**. *Ciência Florestal*, v. 32, n. 1, p. 504-522, 2022.

ZANETTI, R.; VILELA, E. F.; ZANUNCIO, J. C.; LEITE, H. G.; FREITAS, G. D. **Influence of the cultivated species and of the native vegetation on leaf-cutting ant nests density in eucalyptus plantations**. *Pesquisa Agropecuária Brasileira*, v. 35, p. 1911-1918, 2000.

ZANETTI, Ronald. **Manejo de lagartas desfolhadoras**. Notas de aula de ENT 115 – Manejo Integrado de Pragas Florestais. Universidade Federal de Lavras (UFLA), 2006.

ZANUNCIO, J. C. et al. **Population dynamics of Lepidoptera pests in eucalyptus urophylla plantations in the Brazilian Amazonia**. *Forests*, v. 5, n. 1, p. 72–87, 2014.

ZANUNCIO, J. C.; LEMES, P. G.; SANTOS, G. P.; SOARES, M. A.; WILCKEN, C. F.; SERRÃO, J. E. **Population dynamics of lepidoptera pests in Eucalyptus urophylla plantations in the Brazilian Amazonia**. *Forests*, v. 5, p. 72-87, 2014.

ZANUNCIO, J. C. **Manual de pragas em Florestas - Lepidoptera desfolhadores de eucalipto:biologia, ecologia e controle**. [s.l.] Folha de Viçosa Ltda, 1993.

BERNAL, J. S.; MEDINA, R. F.; HEINRICH, G. M. **Applications of economic thresholds in pest management: fundamentals and future needs**. *Annual Review of Entomology*, v. 60, p. 193-211, 2015.

BOTTRELL, D. G.; SMITH, R. F. **The entomological foundation of integrated pest management**. *Annual Review of Entomology*, v. 27, p. 273-296, 1982.

CUNHA, U. S.; SILVA, D. A. L.; LOECK, A. E. et al. **Critérios de decisão para o uso do controle químico em soja transgênica no manejo de pragas**. *Revista Ceres*, v. 58, n. 4, p. 483-487, 2011.

KOGAN, M. **Integrated pest management: historical perspectives and contemporary developments**. *Annual Review of Entomology*, v. 43, p. 243-270, 1998.

MORAIS, G. F.; SANTOS, W. J.; LIMA, J. O. **Sistema de tomada de decisão no controle de pragas em culturas agrícolas**. *Pesquisa Agropecuária Brasileira*, v. 28, n. 10, p. 1195-1205, 1993.

PEDIGO, L. P. **Entomology and pest management**. Englewood Cliffs: Prentice-Hall, 1986.

SILVA, E. B.; AZEVEDO, F. R.; LOPES, M. E. S. et al. **Delimitação de níveis de ação para manejo de pragas em algodão**. *Bragantia*, v. 69, n. 4, p. 927-934, 2010.

SILVA, R. B.; DIAS, S. R. C.; ALVARENGA, R. L. et al. **Métodos de amostragem e nível de controle para curuquerê em feijão**. *Revista de Ciências Agrárias*, v. 60, n. 1, p. 9-15, 2017.

STERN, V. M.; SMITH, R. F.; VAN DEN BOSCH, R.; HAGEN, K. S. **The integrated control concept**. *Hilgardia*, v. 29, n. 2, p. 81-101, 1959.

VALDIVIESO-ROS, C.; ALONSO-SARRIA, F.; GOMARIZ-CASTILLO, F. Effect of the Synergetic Use of Sentinel-1, Sentinel-2, LiDAR and Derived Data in Land Cover Classification of a Semiarid Mediterranean Area Using Machine Learning Algorithms. *Remote Sensing*, v. 15, n. 2, p. 312, 2023.

WANTROBA, Karen Letícia; BARCIK, Lucas Zappia; MADEIROS, Diego Ricardo de; CAMARGO, Mariane Bueno de; GARRETT, Alexandre Techy de Almeida; PESCK, Vagner Alex; UKAN, Daniele. **Detecção de ataque por insetos-praga em plantios de *Eucalyptus* spp. por meio de índices de vegetação.** *Revista Observatorio de la Economía Latinoamericana*, v. 21, n. 9, p. 11497-11515, 2023.