



RICARDO JAIR DE OLIVEIRA

**MONITORAMENTO REMOTO DE FORMIGAS
CORTADEIRAS COM O RADAR SENTINEL-1 EM PLANTIOS
DE EUCALIPTO**

LAVRAS – MG

2025

RICARDO JAIR DE OLIVEIRA

**MONITORAMENTO REMOTO DE FORMIGAS CORTADEIRAS COM O RADAR
SENTINEL-1 EM PLANTIOS DE EUCALIPTO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Entomologia, área de concentração em Ciência de Dados Aplicado a Entomologia, para a obtenção do título de Mestre.

Orientador

Prof. Dr. Alexandre dos Santos

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).**

Oliveira, Ricardo Jair de .

Monitoramento remoto de formigas cortadeiras com o radar sentinel-1 em
plantios de eucalipto / Ricardo Jair de Oliveira. - 2025.
59 p. : il.

Orientador: Alexandre dos Santos

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

1. Monitoramento florestal. 2. Pragas florestais. 3. Radar de abertura sintética. 4.
Sensoriamento remoto. 5. Silvicultura de precisão. I. Santos, Alexandre dos. II.
Universidade Federal de Lavras. III. Título.

RICARDO JAIR DE OLIVEIRA

**MONITORAMENTO REMOTO DE FORMIGAS CORTADEIRAS COM O
RADAR SENTINEL-1 EM PLANTIOS DE EUCALIPTO**

**REMOTE MONITORING OF LEAF-CUTTING ANTS USING THE SENTINEL-1
RADAR IN EUCALYPTUS PLANTATION**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Entomologia, área de concentração em Ciência de Dados Aplicado a Entomologia, para a obtenção do título de Mestre.

APROVADA em 29 de dezembro de 2025.

Dra. Bruna Nascimento de Vasconcellos Externo

Dra. Deborah Valandro de Souza Externo

Documento assinado digitalmente
 **ALEXANDRE DOS SANTOS**
Data: 03/03/2026 11:48:36-0300
Verifique em <https://validar.iti.gov.br>

Orientador

Prof. Dr. Alexandre dos Santos

LAVRAS – MG

2025

AGRADECIMENTOS

Agradeço à Universidade Federal de Lavras (UFLA), ao Departamento de Entomologia (DEN) e ao Programa de Pós-Graduação em Entomologia (PPGEN/UFLA) pela estrutura oferecida e pela oportunidade de realizar este Mestrado.

À minha mãe, expresso minha gratidão especial pelo incentivo constante e pelo suporte em toda a minha trajetória acadêmica e pessoal. Agradeço, igualmente, aos meus amigos que estiveram presentes durante esse percurso e aos meus professores, que sempre me motivaram a seguir adiante.

Ao meu orientador, Alexandre dos Santos, agradeço profundamente pela ajuda, paciência, apoio e incentivo. Estendo meus sinceros agradecimentos a todos que, de alguma forma, contribuíram para a realização deste trabalho.

Aos membros da banca, Dra. Bruna Vasconcellos, Dra. Deborah Valandro, agradeço a participação, apoio, orientações e disponibilidade em colaborar para o aprimoramento desta pesquisa.

Agradeço também a Universidade Federal de Lavras (UFLA) e a todo o seu corpo docente e administrativo que direta ou indiretamente contribuíram para meu crescimento pessoal e profissional.

Agradeço a Capes, CNPq e FAPEMIG pela concessão da bolsa de estudos, que tornou possível a realização do Mestrado.

“Uma imagem vale mais que mil palavras”
(Confúcio)

RESUMO

O Brasil possui mais de 9,93 milhões de hectares de plantações de eucalipto e figura entre os maiores produtores globais de polpa e papel. Nesse contexto, as formigas-cortadeiras representam um dos principais desafios para o setor, devido ao intenso desfolhamento que provoca perda de área foliar, redução da capacidade fotossintética e diminuição do crescimento das árvores. Embora o manejo dessas pragas dependa de monitoramento contínuo, os métodos tradicionais são trabalhosos, custosos e de baixa escalabilidade, reforçando a necessidade de abordagens operacionais mais eficientes. Este trabalho avaliou o uso de dados de radar Sentinel-1 e técnicas de aprendizado de máquina para estimar a cobertura do dossel como indicador indireto da desfolha causada por formigas-cortadeiras, integrando índices SAR (RVI, RATIO e RFDI) previamente selecionados a partir de análises de colinearidade. Três algoritmos supervisionados foram comparados *Neural Networks*, *Random Forest* e *Support Vector Machine* (SVM). As SVM, especialmente nos kernels polinomial e radial, apresentaram o melhor desempenho, com erros médios absolutos próximos a 0,23 e alta estabilidade entre treino e validação. Os resultados demonstraram que, mesmo com resolução de 10 m, o Sentinel-1 é capaz de captar alterações estruturais do dossel associadas à herbivoria, reproduzindo de forma coerente padrões observados em imagens de altíssima resolução (3 cm). A abordagem permitiu identificar gradientes de desfolha e distinguir áreas saudáveis, moderadamente afetadas e severamente danificadas, revelando potencial para aplicação operacional no Manejo Integrado de Pragas. O desenvolvimento deste processo de monitoramento espacial, baseado em big data e processamento em máquinas virtuais em nuvem, contribui para decisões antecipadas, redução de custos e menor necessidade de insumos químicos. Além disso, alinha-se às exigências de certificações ambientais (FSC, Cerflor) e às diretrizes internacionais de manejo sustentável propostas pela FAO, oferecendo uma solução tecnológica aplicada à silvicultura de precisão em larga escala.

Palavras-chave: Monitoramento florestal. Pragas florestais. Radar de abertura sintética. Sensoriamento remoto. Silvicultura de precisão. Aeronaves remotamente pilotadas (RPA).

ABSTRACT

Brazil has more than 9.93 million hectares of eucalyptus plantations and ranks among the world's largest producers of pulp and paper. In this context, leaf-cutting ants constitute one of the main challenges for the sector, as their intense defoliation leads to loss of leaf area, reduced photosynthetic capacity, and decreased tree growth. Although the management of these pests depends on continuous monitoring, traditional methods are labor-intensive, costly, and exhibit low scalability, underscoring the need for more efficient operational approaches. This study evaluated the use of Sentinel-1 radar data and machine learning techniques to estimate canopy cover as an indirect indicator of defoliation caused by leaf-cutting ants, integrating SAR indices (RVI, RATIO, and RFDI) previously selected through collinearity analyses. Three supervised algorithms were compared: Neural Networks, Random Forest, and Support Vector Machine (SVM). SVMs particularly those with polynomial and radial kernels showed the best performance, with mean absolute errors close to 0.23 and high stability between training and validation. The results demonstrated that, even at a 10 m resolution, Sentinel-1 can capture structural changes in the canopy associated with herbivory, coherently reproducing patterns observed in high-resolution imagery (3 cm). The approach enabled the identification of defoliation gradients and the discrimination of healthy, moderately affected, and severely damaged areas, revealing strong potential for operational application in Integrated Pest Management. The development of this spatial monitoring process, based on big data and cloud-based virtual machine processing, supports early decision-making, reduces costs, and decreases the need for chemical inputs. Furthermore, it aligns with the requirements of environmental certifications (FSC, Cerflor) and the sustainable management guidelines proposed by the FAO, offering a technological solution for large-scale precision forestry.

Keywords: Forest monitoring; Forest pests; Synthetic Aperture Radar (SAR); Remote sensing; Precision forestry; Remotely Piloted Aircraft (RPA).

INDICADORES DE IMPACTO

Os resultados desta pesquisa evidenciam implicações relevantes nos âmbitos tecnológico, ambiental, econômico e social, ao demonstrar que dados de Radar de Abertura Sintética (SAR) do Sentinel-1 (10 m de resolução espacial) constituem preditores robustos da cobertura do dossel em plantios de eucalipto. O estudo propõe um arcabouço metodológico operacional, padronizado e reproduzível para estimativa da cobertura vegetal com base em dados SAR gratuitos, processados no Google Earth Engine, configurando um avanço tecnológico para instituições públicas e privadas. Ao reduzir a dependência de inventários de campo e de dados ópticos, a abordagem permite aplicação em larga escala, inclusive em regiões com elevada nebulosidade, disponibilizando um fluxo de trabalho escalável para monitoramento ambiental, auditorias e detecção de alterações estruturais na vegetação. Sob a perspectiva ambiental, o modelo fortalece o monitoramento contínuo da vegetação e a identificação de alterações no dossel decorrentes de distúrbios naturais ou antrópicos, com especial relevância na Amazônia, onde a limitação de dados ópticos é recorrente. Nesse contexto, apresenta elevado potencial para subsidiar políticas de combate ao desmatamento e estratégias de planejamento territorial, ao gerar estimativas rápidas e espacialmente abrangentes. No âmbito econômico, a utilização de dados orbitais de livre acesso aliada à infraestrutura em nuvem reduz significativamente os custos do monitoramento florestal, beneficiando empresas do setor, órgãos reguladores e concessionárias. Socialmente, embora não envolva ações extensionistas diretas, o estudo oferece base técnica para capacitação de profissionais e apoio à gestão territorial municipal e à educação ambiental. Ainda que aplicado na região amazônica, o método é transferível a qualquer área com disponibilidade de dados Sentinel-1, beneficiando técnicos, instituições públicas, empresas, estudantes e pesquisadores, além de alinhar-se aos Objetivos de Desenvolvimento Sustentável 9, 11, 13, 15 e 17, ao promover uma ferramenta robusta, de baixo custo e orientada à gestão sustentável dos recursos naturais.

IMPACT INDICATORS

The results of this research demonstrate relevant technological, environmental, economic, and social implications by showing that Synthetic Aperture Radar (SAR) data from Sentinel-1 (10 m spatial resolution) constitute robust predictors of canopy cover in eucalyptus plantations. The study proposes an operational, standardized, and reproducible methodological framework for estimating vegetation cover using freely available SAR data processed in Google Earth Engine, representing a technological advancement for both public and private institutions. By reducing dependence on field inventories and optical data, the approach enables large-scale application, including in regions characterized by persistent cloud cover, while providing a scalable workflow suitable for environmental monitoring, auditing, and detection of structural vegetation changes. From an environmental perspective, the model strengthens continuous vegetation monitoring and the identification of canopy alterations resulting from natural or anthropogenic disturbances, with particular relevance in the Amazon, where optical data availability is often limited. In this context, it presents significant potential to support anti-deforestation policies and territorial planning strategies by generating rapid and spatially extensive estimates. Economically, the use of open-access orbital data combined with cloud-based infrastructure significantly reduces the costs associated with forest monitoring, benefiting forestry companies, regulatory agencies, and concessionaires. Socially, although the study does not include direct extension activities, it provides a technical foundation for professional training and supports municipal territorial management and environmental education initiatives. While applied in the Amazon region, the method is transferable to any area with Sentinel-1 data availability, benefiting technicians, public institutions, companies, students, and researchers, and aligning with Sustainable Development Goals 9, 11, 13, 15, and 17 by promoting a robust, low-cost tool oriented toward sustainable natural resource management.

SUMÁRIO

1 INTRODUÇÃO	12
2 REFERENCIAL TEÓRICO	16
2.1 Manejo Integrado de Pragas (MIP).....	16
2.2 Sensoriamento Remoto.....	19
2.3 Radar de Abertura Sintética (SAR).....	22
2.4 Machine Learning	24
3 HIPÓTESES	26
4 OBJETIVOS	26
4.1 Objetivo Geral	26
4.2 Objetivos Específicos.....	26
5 MATERIAL E MÉTODOS	26
5.1 Coleta de Dados Experimental.....	26
5.2 Coleta de Dados Validação	28
5.3 Processamento dos Dados	30
6 RESULTADOS	32
7 DISCUSSÃO	38
8 CONCLUSÃO.....	43
REFERÊNCIAS	45

1 INTRODUÇÃO

O Brasil é o maior produtor de polpa de celulose e papel do mundo (Iba, 2024) e para atender esta demanda são necessárias extensas áreas de plantios de eucalipto, que atualmente totalizam 9,94 milhões de hectares. Neste processo produtivo, um dos maiores problemas é o controle de insetos pragas e doenças na cultura, que diminuem a capacidade de produção em áreas afetadas (Oliveira et al., 2014).

O manejo integrado de pragas utiliza vários métodos de controle para manter as populações de insetos abaixo do nível de controle (Ordish, 1966), reduzindo a quantidade e a frequência de aplicação de inseticidas. Dentre as pragas, as formigas cortadeiras *Atta laevigata* (Smith, 1858) e a *Atta sexdens* (Linnaeus, 1758) (Hymenoptera: Formicidae) são as principais em florestas plantadas no Brasil, pois são capazes de forragear durante todo o ano e causar grande prejuízo (Della Lucia et al., 2014).

As formigas cortadeiras representam 75% dos custos e do tempo gasto no controle de pragas (Vilela, 1986). Empresas do setor florestal brasileiro passaram a adotar sistemas de monitoramento de formigas cortadeiras para aumentar a eficiência, diminuir os custos de combate e reduzir o impacto ambiental decorrente de aplicações sucessivas de inseticidas (Zanetti et al., 2000). A amostragem de formigas cortadeiras em florestas plantadas têm sido estudada por diversos autores, entre eles: Zanuncio et al., 2002; Cantarelli et al., 2006; Reis et al., 2010.

A desfolha causada por formigas cortadeiras reduz a área fotossinteticamente ativa, promove um desarranjo fisiológico nas árvores e interfere no seu desenvolvimento, à medida em que fotoassimilados são alocados para a emissão de novas folhas em detrimento do crescimento (Freitas; Berti filho, 1994). Os danos causados por formigas cortadeiras ocasionam alterações nos processos fisiológicos das plantas. Portanto, através desse tipo de resposta que as plantas emitem se faz possível a identificação de injúrias provocadas por esses insetos praga utilizando de imagens obtidas por satélites orbitais (Transon et al., 2018).

Existem vários estudos desenvolvidos com o uso do sensoriamento remoto na detecção de pragas e doenças em plantios comerciais agrícolas e florestais (Meigs; Kennedy; Cohen, 2011; Spruce et al., 2011; Çoban; Ozcelik; Avci, 2014; Sangüesa-barreda et al., 2014; Huang; Zhang, 2016; Santos et al., 2016). O dossel danificado por desfolha se difere do dossel sadio espectralmente, essa diferença pode ser detectada usando imagens de satélites (Moshou et al.,

2005; Jones; Schofield, 2008; Wang; Huang; Luo, 2010), como o Sentinel-2; uma constelação de satélites gêmeos, lançados 2015 e 2017, que juntos, cobrem todas as superfícies terrestres, grandes ilhas e águas continentais e costeiras com revisitação de apenas cinco dias (Zheng et al., 2017). Equipado com um sensor multiespectral de média resolução espacial, o *Multispectral Imager Instruments* (MSI) a bordo do Sentinel-2 cobre um campo de visão de 290 km de raio, fornecendo dados em 13 bandas espectrais no total (Du et al., 2016; Zheng et al., 2017).

Estudos recentes têm demonstrado a aplicabilidade dos dados do Sentinel-2. As imagens do S-2 mostraram que as bandas de resolução espacial de 10 m são adequadas para estimar índice de área foliar de uma variedade de batata (Clevers; Kooistra; Brande, 2017) e monitorar a doença da ferrugem do cafeeiro causada pelo fungo *Hemileia vastatrix*, usando algoritmos de classificação *Random Forest* e PLS-DA (Chemura; Mutanga; Dube, 2016).

Uma nova fase para trabalhos voltados a agricultura, se iniciou com o lançamento do programa *Copernicus* da *European Space Agency* (ESA), dentre as alternativas gratuitas, o sensor RADAR Sentinel-1, parte desta missão, possui excelência no que se refere a disponibilidade de dados com alta resolução espacial e temporal (Csorba et al., 2019). Deste modo, os dados SAR (*Synthetic Aperture Radar*) podem ser considerados um elemento importante neste tipo de análise, independente das condições de cobertura de nuvens presente na área, buscando dessa forma, sanar a lacuna da análise multitemporal de sensores ópticos (Dusseux et al., 2014).

O modo dual-polarização Sentinel-1 (VV-VH), refere-se à transmissão de uma onda polarizada verticalmente com recepção simultânea de polarização vertical e horizontal. Consequentemente, a onda recebida em canais polarizados cruzados (VV-VH) fornece informações sobre um alvo em termos de intensidades de retroespalhamento (ESA, 2018). Vários estudos utilizaram o retroespalhamento para identificação das intensidades de diferentes tipos de culturas (Kussul et al., 2016; Nguyen et al., 2016; Van Tricht et al., 2018; Mandal et al., 2018; Arias et al., 2020), e estimativa de parâmetros biofísicos de culturas (Bousbih et al., 2017; Kumar et al., 2018; Mandal et al., 2020).

A presença frequente de cobertura de nuvens é um desafio constante para a tecnologia de sensoriamento remoto óptico em áreas tropicais, como o território brasileiro (Asner, 2001; Sano et al., 2007), porque os instrumentos ópticos não conseguem coletar dados da superfície da Terra. Entretanto, a vegetação passa por um processo dinâmico, no qual mudanças

significativas na quantidade de biomassa frequentemente acontecem em períodos de tempo relativamente curtos (Wiseman et al., 2014; Whitcraft et al., 2015).

Portanto, as técnicas de imagem por micro-ondas representam alternativas significativas, especialmente quando se utilizam sensores ativos, como os radares de abertura sintética (*Synthetic Aperture Radar* – SAR) (Reigber et al., 2020), uma vez que esses sinais não dependem da luz solar e conseguem penetrar em regiões cobertas por nuvens, neblina e chuva, eles possibilitam a transmissão contínua de dados para o mapeamento da vegetação, sem interrupções (Woodhouse, 2006; Szigarski et al., 2018).

O uso de imagens de SAR do programa Sentinel-1 tem mostrado bons resultados para cartografia de uso da terra a baixo custo (Chatziantoniou; Petropoulos; Psomiadis, 2017). Índices de vegetação como *Radar Vegetation Index* (RVI), *RATIO* que é a razão entre as polarizações VH e VV (Kim; Van Zyl 2009; Van Zyl; Kim, 2011), e o *Radar Forest Degradation Index* (RFDI) (Mitchard et al., 2012; Saatchi 2019), são utilizados como abordagens de quantificação da vegetação.

Outro fator crucial para análises temporais está relacionado à alta frequência de dados de RADAR/SAR, o que garante um número suficiente de observações ao longo de toda a estação de crescimento das plantas. Isso possibilita o mapeamento dos tipos de culturas e sua rotação de forma mais precisa (Vuolo et al., 2018). Para estes fins o programa Sentinel-1, aponta diversas possibilidades, uma vez que oferece resoluções gratuitas sem precedentes com informações mais ricas, aumentando as precisões em comparação com as classificações realizadas apenas com imagens ópticas (Van tricht et al., 2018).

De maneira adicional, técnicas de aprendizado de máquina (*Machine Learning*) possibilitam a fusão de dados provenientes de diversos sensores. Camargo et al., 2019 combinaram informações obtidas por sensoriamento remoto SAR (Radar de Abertura Sintética) e óptico para realizar a classificação do uso e cobertura da terra em uma região no Distrito Federal, no Brasil. Os autores alcançaram resultados mais destacados ao empregarem os classificadores *Random Forest* (RF) e *Support Vector Machine*. Dentre esses classificadores, o *Random Forest* se destaca devido à sua escalabilidade simplificada, repetibilidade consistente e requisitos computacionais reduzidos (Camargo et al., 2019; Abdi et al., 2022).

Essas qualidades viabilizam a criação de modelos particulares para distintas regiões, levando em consideração as particularidades e as dinâmicas locais, ao mesmo tempo que não interferimos nos modelos mais abrangentes. Isso também permite a parametrização de

informações relacionadas à resposta de retroespalhamento e à reflectância espectral da vegetação (Abdi et al., 2022).

A *Random Forest* (RF) representou um avanço dentre as técnicas de machine learning baseadas em árvores de decisão para a classificação por introduzir robustez a resultados obtidos por uma grande quantidade de árvores, sem causar sobreajuste no modelo (Chollet; Allaire, 2018).

As *Neural Networks* (NN) também são uma abordagem do tipo aprendizado de máquina profundo ou *deep learning* que é utilizada pela alta capacidade de aprendizado por intermédio de uma base de dados de exemplos e realizar inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho (Ferneda, 2006). Essa metodologia tem sido atualmente empregas para auxiliar no manejo de pragas para a identificação de insetos em cultivos (Xia et al., 2018) e detecção de plantas de Pinus com perturbações fisiológicas com o emprego de imagens de satélite multiespectral RapidEye combinadas a imagens RGB obtidas com veículos aéreos não tripulados (Dash et al., 2018).

Alguns estudos têm sido realizados na tentativa de relacionar níveis de desfolhamento das árvores ou densidades de formigueiros com perdas em volume de madeira (Naccarata, 1983; Hernandez; Jaffe, 1995; Zanetti et al., 2003). O desfolhamento das árvores e a presença de formigueiros podem afetar negativamente o crescimento e a produção de madeira, causando perdas significativas.

A avaliação da severidade de pragas em campo através do sensoriamento remoto pode contribuir no processo de tomada de decisão de medidas de mitigação relevantes, como aplicação de inseticidas (Mutanga; Dube; Galal, 2017), pois poderá monitorar as áreas afetadas e a extensão dos danos causados por formigas cortadeiras em tempo útil e indicar áreas com real necessidade de controle, como exigido pelos órgãos certificadores florestais FSC-*Forest Stewardship Council* (Isering; Neumeister, 2010; Rocha et al., 2014; FSC, 2023) e o Programa Brasileiro de Certificação Florestal (CERFLOR) (Santos et al., 2016; Zanuncio; Lemes; Antunes, 2016).

Dentro deste contexto, este trabalho tem como objetivo desenvolver uma nova metodologia de monitoramento de formigas cortadeiras com radar de abertura sintética em plantios de eucalipto com o uso de técnicas de machine learning (ML) aplicadas a big data espacial com o emprego de máquinas virtuais (VM) em nuvem.

2 REFERENCIAL TEÓRICO

2.1 Manejo Integrado de Pragas (MIP)

O Manejo Integrado de Pragas (MIP) configura-se como uma estratégia consolidada de proteção fitossanitária, adotada amplamente desde sua formulação na segunda metade do século XX, sendo desenvolvido como resposta ao uso indiscriminado de pesticidas e ao surgimento de resistência em populações de pragas, o MIP propõe uma abordagem mais racional e sustentável no manejo dessas espécies, dessa forma a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO) define o MIP como a análise criteriosa de todas as técnicas disponíveis de controle, promovendo a integração de métodos que desestimulem o aumento populacional das pragas, ao mesmo tempo em que mantêm o uso de pesticidas em níveis economicamente justificáveis, onde essa abordagem busca reduzir os riscos à saúde humana e ao meio ambiente, assegurando o desenvolvimento de culturas saudáveis com mínima interferência nos agroecossistemas e incentivando os mecanismos naturais de regulação biológica (FAO, 2020).

Essa abordagem pode ser implementada por meio da amostragem e do monitoramento oportuno das pragas, com o objetivo de estimar suas densidades populacionais e a tomada de decisões de manejo mais precisas, integrando o uso criterioso de pesticidas com uma diversidade de métodos sustentáveis, entre eles: uso de armadilhas e a aplicação de feromônios sintéticos; o controle biológico, seja pela conservação ou pela liberação de inimigos naturais artrópodes; o manejo agrônomo e cultural, baseado na modificação do habitat; e o uso de cultivares resistentes (Meissle et al. 2011; Ragsdale et al. 2011).

A predição de pragas consiste no monitoramento sistemático e na análise de dados biológicos e ambientais com o objetivo de antecipar surtos populacionais, baseando-se na integração de conhecimentos da biologia, matemática, estatística e outras disciplinas correlatas, visando identificar padrões temporais e espaciais de ocorrência, essa predição precisa e oportuna das infestações permite aos produtores adotarem medidas de controle no momento mais adequado, aumentando a eficácia das ações e evitando perdas econômicas, contribuindo para a redução do uso indiscriminado de pesticidas, mitigando os impactos negativos sobre o meio ambiente e a saúde humana, logo, a previsão de pragas se apresenta como uma ferramenta essencial dentro do Manejo Integrado de Pragas, especialmente quando associada a tecnologias

emergentes de coleta e análise de dados em larga escala (Hu et al., 2019; Machekano et al., 2019; Ponomarev et al., 2019).

Os métodos tradicionais de monitoramento baseiam-se na realização de levantamentos de campo sistemáticos, nos quais as informações sobre a presença, a densidade e a distribuição de pragas são obtidas por meio de observações diretas em áreas amostrais, essas atividades envolvem, geralmente, caminhamentos, inspeções visuais e o uso de armadilhas específicas, demandando mão de obra especializada e considerável esforço logístico (Ebrahimi et al., 2017). Embora eficazes em pequena escala pois possibilita obter informações detalhadas sobre pragas, tais métodos apresentam limitações em termos de custo, exigem muita mão de obra, tempo e cobertura espacial, especialmente em áreas extensas ou de difícil acesso (Dong et al., 2019).

O Brasil ocupa a liderança mundial na produção de celulose e papel, tendo o setor florestal, majoritariamente, em plantios de eucalipto que de acordo com a Indústria Brasileira de Árvores (IBA) a área total ocupada por esses plantios alcança 9,94 milhões de hectares (Ibá, 2024). Para atender à crescente demanda industrial, é necessário manter elevados padrões de produtividade, o que exige um controle eficiente de fatores bióticos, como pragas e doenças, nessa condição, a ocorrência de insetos-praga representa um dos principais entraves ao pleno desenvolvimento da cultura, comprometendo significativamente a produção em áreas infestadas (Oliveira et al., 2014).

Dentre as principais pragas que afetam florestas plantadas no Brasil, destacam-se as formigas cortadeiras *Atta laevigata* (Smith, 1858) e *Atta sexdens* (Linnaeus, 1758) (Hymenoptera: Formicidae), essas espécies apresentam elevada capacidade de forrageamento ao longo de todo o ano, independentemente de variações sazonais, o que lhes confere grande potencial de dano, essa constante atividade desses insetos pode comprometer severamente o desenvolvimento das árvores, resultando em prejuízos significativos à produtividade florestal (Della Lucia et al., 2014).

As formigas cortadeiras, consideradas as principais pragas das plantações florestais no Brasil, removem folhas, flores, brotos e galhos, transportando-os para o interior de seus ninhos (Mariconi, 1981). Com isso, provocam perdas diretas, como a morte de mudas e a redução do crescimento das árvores, além de perdas indiretas, ao comprometer a resistência das plantas a insetos e patógenos (Zanuncio et al., 1996).

O impacto das formigas cortadeiras é particularmente severo nos três primeiros anos de desenvolvimento das plantas, período em que as mudas apresentam maior suscetibilidade à

perda de área foliar (Zanetti et al., 2014). Em cultivos de *Eucalyptus grandis*, uma única desfolha completa já é suficiente para comprometer significativamente o crescimento (Matrangolo et al., 2010). Quando ocorrem duas desfolhas consecutivas, há risco elevado de mortalidade das plantas (Lewis; Norton, 1973). Mesmo após os três anos iniciais, indivíduos adultos ainda podem sucumbir caso sofram três episódios consecutivos de desfolha total, evidenciando o potencial destrutivo dessas pragas e a necessidade de estratégias de monitoramento e controle desde os estágios iniciais do plantio (Mendes Filho, 1979).

Em mudas de *Eucalyptus grandis*, o ataque das formigas cortadeiras inicia-se, geralmente, na porção apical da planta, as folhas jovens e os ponteiros são os primeiros alvos do corte, sendo posteriormente seguidos por folhas mais desenvolvidas e estruturas próximas à base, esse padrão de desfolha ascendente para descendente acentua o estresse fisiológico da planta, especialmente em estágios iniciais de desenvolvimento, comprometendo sua capacidade de recuperação e aumentando o risco de mortalidade (Anjos et al., 1998).

As perdas provocadas por formigas cortadeiras variam conforme a idade da planta e a intensidade do ataque, em alguns casos de ataques intensos e constantes, as perdas podem chegar a 100% da produção (Reis Filho et al., 2011). Quando o ataque ocorre durante a fase inicial do plantio, as perdas podem ser irreversíveis, comprometendo significativamente o estabelecimento e o desenvolvimento das mudas, o que dificulta a recuperação da área afetada (Anjos et al., 1993).

Além da redução na produtividade, os prejuízos causados pelas formigas cortadeiras incluem a diminuição da resistência das plantas, tornando-as mais vulneráveis ao ataque de outras pragas e ao desenvolvimento de doenças (Ferreira, 1989). Soma-se a isso o elevado custo associado às atividades de monitoramento e controle dessas pragas, o que reforça a importância de estratégias eficientes e integradas para minimizar os impactos econômicos e ambientais (Zanuncio et al., 1996).

Vilela (1986) destacou que as formigas cortadeiras correspondem a aproximadamente 75% dos custos e do tempo investidos nas atividades de controle de pragas em florestas plantadas. Alípio (1989) relatou que as formigas cortadeiras representam cerca de 30% dos gastos com a floresta até o terceiro ciclo produtivo, valor que, segundo Rezende et al. (1983), equivale a aproximadamente 7,4% do preço da madeira em pé.

A desfolha causada pelas formigas cortadeiras reduz a área fotossinteticamente ativa das árvores, provocando um desequilíbrio fisiológico que compromete seu desenvolvimento

(Freitas; Berti filho, 1994). Portanto, através desse tipo de resposta que as plantas emitem se faz possível a identificação de injúrias provocadas por esses insetos praga utilizando de imagens obtidas por satélites orbitais (Transon et al., 2018).

2.2 Sensoriamento Remoto (SR)

O sensoriamento remoto é uma tecnologia que permite a coleta de dados sem contato direto com o sujeito, utilizando sensores para medir ou detectar vários tipos de energia, como radiação eletromagnética e sinais acústicos, emitidos, refletidos ou espalhados pelo objeto sob investigação (Campbell; Wynne, 2011).

O sensoriamento remoto é amplamente utilizado em aplicações como reconhecimento militar, análise de riscos naturais, detecção de mudanças no uso e cobertura do solo, medição da distribuição do gelo marinho, agricultura de precisão e estimativa e mapeamento de estoques de carbono (Navalgund et al., 2007; Weiss; Duveiller, 2020).

As propriedades primárias do alvo detectado pelo sensor nessas aplicações estão na forma de assinaturas espaciais, espectrais, temporais e de polarização (Roy et al., 2017). Muitos modelos de processos físicos foram desenvolvidos para quantificar as relações de dados entre sensor e alvo (Zhang et al., 2022).

Imagens de sensoriamento remoto, com resolução espacial e temporal variável, com a vantagem de monitoramento não destrutivo, são amplamente aplicadas na pesquisa florestal (Chander et al., 2010). As técnicas de sensoriamento remoto têm duas vantagens não fungíveis: monitoramento contínuo da dinâmica da biomassa florestal (Keles, 2016; Badreldin; Sanchez-Azofeifa, 2015) e mapeamento da heterogeneidade da biomassa florestal (Ma; Liu, 2015).

Devido às restrições de resolução espacial e à precisão da avaliação de dados de sensoriamento remoto, o desenvolvimento da estimativa da biomassa florestal por sensoriamento remoto em escalas de árvores individuais e populacionais tem sido relativamente lento (Wang et al., 2010). Com melhorias na resolução espacial e espectral da plataforma (por exemplo, QuickBird e Worldview2), juntamente com o desenvolvimento contínuo de técnicas de sensoriamento remoto, o potencial para identificar limites de copas de árvores individuais (Krofcheck et al., 2016) e espécies de árvores (Wang et al., 2016) foi demonstrado.

As florestas desempenham um papel crucial na manutenção da biodiversidade e do equilíbrio ecológico da Terra, regulando o clima e fornecendo uma ampla gama de recursos

para uso humano, o mapeamento de florestas é uma ferramenta essencial para compreender, gerir e proteger esses ecossistemas vitais (Chehreh et al., 2023). Os mapas florestais são uma ferramenta importante para a gestão de recursos (Camarretta et al., 2020).

No entanto, o monitoramento de espécies de árvores é uma tarefa desafiante, demorada, dispendiosa e limitada a uma pequena (de Lima et al., 2022). A detecção remota pode contribuir significativamente para enfrentar estes desafios e existe um apelo claro para integrar novas tecnologias deste campo na silvicultura e na ecologia (Lechner et al., 2020; Cavender-Bares et al., 2022).

As técnicas de sensoriamento remoto estão sendo cada vez mais utilizadas para mensurar qualquer perturbação nas florestas devido às suas vantagens, especialmente em termos de escala espacial, em comparação com os métodos tradicionais (Harris et al., 2006; Liu et al., 2020). As técnicas de sensoriamento remoto não são destrutivas e podem fornecer informações sobre as florestas sem qualquer contato físico (Govender et al., 2009; Virnodkar et al., 2020).

A tecnologia de sensoriamento remoto pode medir múltiplos indicadores de estresse hídrico, como conteúdo de água, pigmentos foliares, temperatura do dossel e fluorescência da clorofila, o que pode fornecer uma imagem mais abrangente da saúde da floresta e do uso da água (Clay et al., 2006; Sepulcre-Cantó et al., 2006; Liu et al., 2020; Ahmad et al., 2021).

O princípio do sensoriamento remoto na observação da vegetação envolve o uso de sensores para medir os diferentes comprimentos de onda da radiação eletromagnética emitida ou refletida pelas plantas e seu ambiente circundante (Huete et al., 2004; Wang et al., 2010). A vegetação saudável reflete e absorve diferentes comprimentos de onda de uma forma característica, que pode ser detectada por instrumentos de sensoriamento remoto (Gausman, 1977; Huete et al., 2004).

Ao analisar os padrões de radiação eletromagnética refletida ou emitida, os instrumentos de sensoriamento remoto podem fornecer informações sobre propriedades da vegetação, como índice de área foliar (IAF), teor de clorofila, teor de água e biomassa (Curran et al., 1990; Ceccato et al., 2001). Essas informações podem ser usadas para monitorar a saúde da vegetação, identificar áreas de estresse da vegetação e estimar a produtividade das colheitas (Huete et al., 2004; Wang et al., 2010).

Em plantações, os levantamentos de campo são importantes para a detecção de pragas e doenças, porém exigem muita mão de obra, consomem muito tempo e são impraticáveis em

áreas com terrenos particularmente íngremes. Em vez disso, técnicas de agricultura de precisão, utilizando sensoriamento remoto de alta resolução por veículos aéreos não tripulados (VANT) com uma variedade de sensores diferentes, ou mesmo câmeras convencionais vermelho-verde-azul (RGB), levariam a um monitoramento mais barato e prático da saúde florestal (Lee, et al., 2010; Abdollahnejad; Panagiotidis, 2020).

O uso de VANTs, juntamente com análises de big data e inteligência artificial, oferece novas abordagens para a fenotipagem de plantas (Ballesteros et al., 2014; LeCun et al., 2015; Senthilnath et al., 2017) determinação da altura da planta (crescimento) (Malambo et al., 2018; Hunt et al., 2016) para avaliar variedades de plantas (Ampatzidis et al., 2019) e detecção de pragas (Abdulridha et al., 2019) e doença (Sugiura et al., 2016; Rodríguez et al., 2021).

Dados de sensoriamento remoto têm sido usados para fenotipagem de plantas, incluindo índices para avaliar o estado de saúde das plantas (Peña et al., 2015; Rasmussen, et al., 2016; Sugiura et al., 2016; Dash et al., 2017; Del-Campo-Sanchez et al., 2019).

Além das plataformas e sensores, os métodos de processamento de dados são outra parte fundamental do processo de mapeamento com sensoriamento remoto (Holzinger et al., 2022). A análise de dados e o aprendizado de máquina são ferramentas poderosas que estão sendo cada vez mais utilizadas para mapear e compreender florestas, permitindo o processamento e a interpretação eficientes de grandes quantidades de dados, que podem ser usados para criar mapas precisos e detalhados da estrutura e composição da floresta (Chehreh et al., 2023).

Muitas aplicações florestais e processos de classificação por aprendizado de máquina são baseados em dados de satélite (por exemplo, MODIS, Landsat e Sentinel-2) que permitem a cobertura de vastas áreas (Beloïu et al., 2023). Para a identificação de espécies de árvores, esses dados de satélite têm alta resolução temporal, mas baixa resolução espacial, dificultando a identificação precisa de espécies de árvores individuais (Waser et al., 2021). No entanto, a crescente disponibilidade de dados de sensoriamento remoto de alta resolução, combinada com o uso de algoritmos de Aprendizagem Profunda (DL), como Redes Neurais Convolucionais (CNNs), está se mostrando extremamente útil para análises detalhadas de ecossistemas em larga escala (Brodrick et al., 2019; Kattenborn et al., 2021).

2.3 Radar de Abertura Sintética (SAR)

As primeiras tentativas de uso do sensoriamento remoto para análise da cobertura vegetal surgiram na década de 1970, após o lançamento do ERTS (Landsat 1), satélite pioneiro de recursos naturais, fundamentando o sensoriamento remoto óptico passivo nas variações de observação e reflexão da luz solar pelas plantas em diferentes faixas espectrais, contexto no qual o NDVI (Índice de Vegetação por Diferença Normalizada), um dos primeiros índices propostos, passou a estimar a presença vegetal e permanece como o indicador mais utilizado para detectar biomassa verde viva a partir de dados multiespectrais. (Rouse et al., 1974; Tucker, 1979).

Nas décadas seguintes, surgiram diversos índices ópticos para relacionar o espectro do povoamento florestal à sua produtividade (Hall et al., 2006; Lu et al., 2004; Ji et al., 2012; Lu et al., 2005), porém esses métodos ópticos têm limitações, como a incapacidade de captar a estrutura vertical da vegetação, ou que comprometem a precisão na estimativa da estrutura florestal.

Recentemente, estudos exploram radares de abertura sintética (SAR) para avaliar estrutura florestal (Champion et al., 2013; Stankevich et al., 2017). Os dados SAR penetraram no dossel florestal o que nos permite analisar e estudar as estruturas florestais de forma mais adequada, melhorando o monitoramento florestal, superando as restrições ópticas (Movchan et al., 2023).

Atualmente é possível obter imagens de satélite por meio de diversas plataformas espalhadas por toda a superfície terrestre (Kuck et al., 2021). Os avanços tecnológicos em sensores e plataformas de satélite vêm aumentando continuamente as resoluções espaciais e temporais desses dispositivos, o que reduz a janela de tempo para a captura de dados em um ponto específico da Terra. Isso possibilita um monitoramento e análise mais constantes da dinâmica territorial em diferentes regiões do mundo (Monsalve-Tellez et al., 2022).

O Programa *Copernicus*, apoiado pela Agência Espacial Europeia (ESA), oferece uma plataforma global de monitoramento por satélite chamada Sentinel, que captura imagens de toda a superfície terrestre a cada seis dias, abrangendo diferentes regiões do espectro eletromagnético (ESA, 2015). O Sentinel-1, equipado com um sensor SAR-C, opera na faixa de micro-ondas do espectro eletromagnético (ESA, 2013).

Os sensores SAR têm a capacidade de monitorar a vegetação mesmo através das nuvens, interagindo com diferentes partes das plantas dependendo da frequência utilizada (Singhal et al., 2024). A banda C corresponde à faixa de micro-ondas entre 4 e 8 GHz (Peebles, 1998), com comprimento de onda em torno de 5,5 cm, interagindo principalmente com folhas e pequenos galhos. O SAR em banda C é sensível à folhagem e sua capacidade de não ser facilmente atenuado pela cobertura de nuvens permite capturar o ciclo fenológico anual completo das florestas (Singhal et al., 2024).

Sensores SAR são sensores ativos e coerentes, pois emitem pulsos de radiação que viajam até a superfície terrestre, são retroespalhados pelos alvos e detectados pelo sensor em um único comprimento de onda (Woodhouse, 2006; Saatchi, 2019), e por serem monocromáticos, as interações com diferentes alvos ocorrem por meio das polarizações mensuráveis pelo sensor, como HH (emissão e detecção de ondas horizontalmente polarizadas), HV, VV e VH, cujos distintos mecanismos de retransmissão que podem acontecer em uma mesma cena sob diferentes polarizações, diversos autores desenvolveram índices de vegetação específicos para imagens SAR.

O primeiro índice de vegetação para SAR foi o RVI (índice de vegetação de radar) (Kim, Y; van Zyl, 2000) que integra dados polarimétricos completos (HH, HV, VV e VH) de imagens na banda L. Chang et al., (2018) aprimoraram o RVI com o PRVI (RVI polarizado), adicionando o grau de polarização (DoP). Já para sensores de banda C, como o Sentinel-1, surgiu o DPSVI (índice de vegetação SAR de polarização dupla), que emprega relações empíricas entre VV e VH para estimar a biomassa de cultivos e vegetações (Periasamy, 2018).

Para contornar a saturação do sinal de banda C em florestas, dos Santos et al. (2021) modificaram o DPSVI, criando o DPSVIm com maior sensibilidade a biomassas densas. Mandal et al. (2020) introduziram o DpRVI (RVI de polarização dupla) para rastrear a fenologia de culturas anuais em banda C, aplicando o conceito de DoP. Em comum, esses índices captam variações na polarização do sinal de radiação ao interagir com estruturas volumétricas e complexas, como a vegetação (Santos, 2023).

Atualmente, múltiplos satélites com sistemas SAR operam em órbita, ampliando a disponibilidade de sensores que combinam diversas frequências em missões como TerraSAR-X/TanDEM-X e Cosmo-SkyMed (banda X, ~1 cm), RADARSAT-2 e Sentinel-1 (banda C, ~5 cm), ALOS/PALSAR e ALOS-2 (banda L, ~23 cm), esses sistemas viabilizam a obtenção de dados SAR em diferentes frequências e polarizações, incluindo dados polarimétricos

(Hagenseiker; Waske, 2018), o que otimiza o mapeamento de uso e cobertura do solo, especialmente de áreas florestais.

2.4 Machine Learning (ML)

Aprendizado de máquina compreende um conjunto de metodologias, ferramentas e algoritmos que ensinam máquinas a analisar dados, identificando padrões ocultos para formular previsões precisas, tendo como propósito fundamental promover o aprendizado autônomo por meio de dados, dispensando a programação explícita dos computadores, assim, máquinas treinadas em conjuntos de dados aplicam esses padrões a novas informações, aprimorando suas previsões (Wassouf et al., 2020). Os métodos mais comuns de aprendizado de máquina agrupam-se em três tipos principais: aprendizado por reforço, supervisionado e não supervisionado (Hall et al., 2022; Jain et al., 2020).

A aprendizagem de máquina destaca-se atualmente como uma das áreas de maior expansão tecnológica (Jordan; Mitchell, 2015). É adequado para problemas que são muito complexos ou vastos para abordagens tradicionais, ou para os quais não há nenhuma solução conhecida, oferecendo uma nova possibilidade de aprender diretamente a partir de dados, em oposição às abordagens de modelagem tradicionais de definir explicitamente regras/funções para descrever relacionamentos e padrões em dados (Natras; Schmidt, 2021).

Atualmente, os classificadores mais empregados em análises de sensoriamento remoto são aqueles baseados em métodos não paramétricos (Raczko; Zagajewski, 2017), como as *Neural Networks* (NN), que demandam elevado poder computacional, mas apresentam resultados robustos (Quang et al., 2020). Também se destacam a *Support Vector Machine* (SVM) (Vapnik, 1995; Arenas-Castro et al., 2014) e a *Random Forest* (RF) (Breiman, 2001; Boateng et al., 2020). Ainda assim, em áreas extensas e relativamente homogêneas, algoritmos paramétricos podem produzir resultados satisfatórios (Li et al., 2013).

Diversos autores apontam que os classificadores SVM e RF oferecem alta acurácia aliada ao baixo tempo de processamento (Hauglin; Ørka, 2016; Wessel et al., 2018). Esses algoritmos são amplamente utilizados na classificação de espécies lenhosas, sobretudo em dados multiespectrais, devido às propriedades já mencionadas (Belgiu; Drăgu, 2016; Cohen et al., 2020). Banskota et al. (2014) demonstraram que RF e SVM são capazes de gerar mapas detalhados, destacando-se pela eficiência e facilidade de processamento. Além disso, um fator

determinante para o aumento da precisão da classificação é o uso integrado de imagens multitemporais e índices de vegetação, que pode elevar a acurácia geral de 71% para até 97% (Hill et al., 2010).

Utilizando cenas Landsat TM adquiridas na primavera e no outono, Shao et al. (2014) identificaram duas espécies arbóreas e dois tipos florestais, alcançando acurácia de 89%. Resultados semelhantes foram observados por Zhu e Liu (2014), que, aplicando o algoritmo Support Vector Machine, diferenciaram três classes florestais com uma acurácia global de 90,5%. Pasquarella et al. (2018) empregaram o algoritmo *Random Forest* para discriminar oito tipos de floresta, avaliando diferentes conjuntos multitemporais compostos por imagens de diversos meses; os autores obtiveram valores de acurácia do produtor (PA) variando entre 51% e 90%.

Li et al. (2013), utilizando *Decision Trees*, *Random Forest* e *Support Vector Machine* em imagens Landsat TM, separaram três tipos florestais, registrando acurácias entre 79,1% e 88,2%, dentre os métodos testados, o *Random Forest* apresentou o melhor desempenho, enquanto as *Decision Trees* obtiveram os piores resultados.

Esses estudos demonstram que espécies lenhosas apresentam um conjunto distintivo de características espectrais que pode ser detectado por meio de imagens de satélite (Kycko et al., 2018). Além disso, o uso de índices de vegetação de sensoriamento remoto e de variáveis derivadas de modelos de elevação contribui para uma identificação acurada de espécies e tipos florestais em diferentes zonas biogeográficas. Naturalmente, os melhores desempenhos são observados em florestas manejadas, caracterizadas por áreas densas e homogêneas, onde potenciais fontes de distúrbio são rapidamente controladas, garantindo condições ambientais ideais para o desenvolvimento das árvores (Zagajewski et al., 2021).

É nesse contexto que as tecnologias emergentes podem desempenhar um papel decisivo, suprimindo lacunas e limitações inerentes às abordagens tradicionais de coleta e análise de dados um aspecto fundamental para a gestão e conservação florestal eficazes. O setor florestal tende a se beneficiar amplamente da capacidade da tecnologia em impulsionar a inovação, permitindo sua adoção em diferentes regiões e escalas, além de acelerar de forma substancial o ritmo de implementação de soluções (Shivaprakash et al., 2022).

3 HIPÓTESES

O emprego de técnicas de aprendizado de máquina ou *machine learning* (ML) aplicadas a imagens de radar, com o uso de big data espacial e máquinas virtuais (VM) em ambiente de nuvem, pode produzir processos precisos, rápidos e de fácil operacionalização para o monitoramento de formigas cortadeiras em larga escala espacial em plantios de eucalipto?

4 OBJETIVOS

4.1 Objetivo Geral

Desenvolver uma nova metodologia de monitoramento da desfolha causada pelas formigas cortadeiras em plantios de eucalipto com o uso de Radar de Abertura Sintética (SAR) integrando técnicas de *machine learning* (ML) aplicadas a big data espacial com o emprego de máquinas virtuais (VM) em nuvem.

4.2 Objetivos Específicos

- Realizar o ajuste e seleção de modelos empregando técnicas de machine learning (ML), sendo *Random Forest* (RF), *Support Vector Machine* (SVM) e *Neural Networks* (NN) com o uso de máquinas virtuais (VM) aplicados a dados de imagem do satélite Sentinel-1 utilizando-se uma base de dados experimental;
- Emprego dos modelos de ML para predição da ocorrência atual em média escala aplicados a dados de imagem radar do satélite Sentinel-1 e posterior validação/confirmação da classificação estimada em campo.

5 MATERIAL E MÉTODOS

5.1 Coleta de Dados Experimental

Na primeira etapa do estudo foi utilizado uma área plantada de *Eucalyptus* spp. da empresa Klabin, onde foi selecionado um talhão de 40 hectares para realização do experimento

situado no município Ribas do Rio Pardo, Estado do Mato Grosso do Sul, com coordenada do centroide de 20°31'53.54"S e 54° 0'23.40"O.

Realizou-se um levantamento aerofotogramétrico para obtenção de imagens UAV-RGB para criação de um ortomosaico georreferenciado com o objetivo de estabelecer uma comparação com as imagens obtidas pelo satélite Sentinel-1 SAR. Após gerar o ortomosaico georreferenciado obteve-se uma imagem com resolução espacial de 3,19 cm, posteriormente fez-se a segmentação semântica da imagem onde o intuito é separar a vegetação do solo, extraíndo apenas a informação da vegetação. A segmentação semântica reconhece e analisa a imagem no nível do pixel e atribui a cada pixel uma classe específica a que pertence (Fleet, 2007).

Imagens de radar da área de estudo foram obtidas da banda C a bordo do satélite Sentinel-1 (S1) Nível-1 *Ground Range Detected* (GRD) que realiza a aquisição da polarização VV e VH com 10 metros de resolução espacial (ESA, 2018). A combinação das polarizações VV e VH é relevante porque cada uma responde a diferentes mecanismos de espalhamento. A polarização VV é mais sensível à estrutura dominante e à rugosidade média da copa, enquanto a VH está fortemente associada ao espalhamento volumétrico múltiplo dentro do dossel. O uso conjunto dessas polarizações permite capturar alterações estruturais da vegetação de forma mais robusta do que a utilização isolada de uma única polarização.

A aquisição das imagens do satélite Sentinel-1 (S1) Nível-1 *Ground Range Detected* (GRD) foram obtidas utilizando a plataforma de análise geoespacial com computação em nuvem *Google Earth Engine* (GEE). Trata-se de uma plataforma que possui alta capacidade de armazenamento e processamento de imagens de satélites, permite ao usuário obter diversas imagens através de rotinas e padrões de programação possibilitando realizar diversas análises espaço-temporais, a nível regional, estadual, nacional e global, com velocidade muito maior do que com as técnicas de SIG convencionais.

Na plataforma GEE, foi criado um script utilizando linguagem de programação *Python* contendo as informações definindo o satélite utilizado, a área a ser utilizada, a temporalidade das imagens, as polarizações a serem adquiridas e o sensor. A delimitação do talhão foi inserida como arquivo shapefile na plataforma, onde a delimitação do talhão serve de recorte para que as imagens a serem inseridas apareçam apenas dentro dos limites estabelecidos no arquivo de área shapefile. Tendo como produto a aquisição das imagens na banda C, polarização VV e VH, sensor IW com duas polarizações, e 10 m de resolução espacial.

5.2 Coleta de Dados Validação

Na segunda etapa de coleta de dados para validação da metodologia foram coletados dados de infestação de formigas cortadeiras, realizando um censo da área em um plantio de eucalipto de 2,27 hectares de *Eucalyptus* sp. situado no Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT) - Campus Cáceres, município de Cáceres, Estado de Mato Grosso, com coordenada do centroide de 16°7'22.296''S e 57°41'26.484''O. Os dados de infestação de formigas cortadeiras em áreas de plantio de eucalipto foram obtidos por meio de censo dos ninhos de formigas cortadeiras da área (Figura 1).

Figura 1 - Dimensão de um formigueiro do gênero *Atta* (Hymenoptera: Formicidae) Saúva-cabeça-de-vidro.



Fonte: Do autor (2024)

Os formigueiros foram demarcados com estaca e tiveram as suas dimensões mensuradas na maior largura e no maior comprimento com auxílio de trena (Figura 2). Os ninhos foram inspecionados em relação à sua atividade e amostras da casta dos soldados foram coletadas para posterior identificação da espécie no Laboratório de Fitossanidade (FitLab) do IFMT Campus Cáceres. Esta mensuração foi realizada com o propósito de observar a evolução dos ninhos ao longo da execução do projeto.

Figura 2 - Mensuração da largura e comprimento do formigueiro.



Fonte: Do autor (2024)


Imagens da banda C a bordo do satélite Sentinel-1 (S1) foram obtidas da área experimental com intervalo de 12 dias. Foram adquiridas também imagens UAV-RGB em intervalos de 12 dias por meio de voos periódicos utilizando o drone Phantom 4 Advanced com o objetivo de estabelecer uma comparação com as imagens obtidas pelo satélite Sentinel-1 SAR. Foram obtidas as imagens Nível-1 Ground Range Detected (GRD) que realiza a aquisição da polarização VV e VH com 10 metros de resolução espacial (ESA, 2018).

As imagens obtidas pelo Drone Phantom 4 Advanced foi utilizada para a criação do ortomosaico que foi responsável pela confecção de um gráfico que mostra a comparação entre as imagens obtidas pelo satélite Sentinel-1 SAR com as imagens do Drone. Os veículos aéreos

não tripulados (VANT) estão revolucionando pesquisas e serviços técnicos no âmbito da agricultura de precisão, proporcionando produtos (imagens sintéticas ou multiespectrais) com alta resolução espacial e temporal para o monitoramento da produção agrícola (Jorge, 2014). Para a realização dos voos periódicos foi necessário a utilização da ferramenta auxiliar DroneDeploy para realização de voo automatizado.

A confecção do ortomosaico se deu pela plataforma Agisoft-Metashape que é uma ferramenta para pipeline de fotogrametria. Apesar da classificação manual das imagens ser considerada precisa, segundo Crosta (1999) mesmo a técnica de interpretação visual ser a mais utilizada, há uma forte tendência ao uso da classificação computacional, devido a rapidez e facilidade de obtenção de resultados (Crosta, 1999).

Figura 3 - Ortomosaico da área de estudo.



Fonte: Do autor (2024)

5.3 Processamento dos Dados

Após a segmentação da imagem RGB e extração da vegetação (cobertura do dossel) foi realizado o cálculo da cobertura vegetal via correlação entre a segmentação e a imagem de radar. Em complementação foram gerados índices de vegetação utilizados como fatores nas

análises de correlação para seleção de variáveis explicativas. Os índices de vegetação utilizados foram RVI, RATIO e RFDI (Tabela 1). Os índices RVI, RATIO e RFDI foram escolhidos por representarem mecanismos físicos distintos da interação radar-vegetação.

O RVI é sensível ao espalhamento volumétrico, refletindo a presença e densidade da vegetação. O RATIO (VV/VH) evidencia mudanças estruturais na copa, destacando a relação entre espalhamento co-polarizado e cruzado. O RFDI, por sua vez, foi concebido para detectar descontinuidade do dossel e perda de folhagem. Esses índices sintetizam informações estruturais relevantes, reduzindo redundância e aumentando a capacidade de estimar cobertura vegetal.

Os valores das variáveis de resposta foram normalizados por equalização de faixa, entre 0 e 1 para atenuar os efeitos da ordem de magnitude dentro ou entre as polarizações e índices de vegetação, utilizando a equação (Langford *et al.*, 2019): $y_i = (x_i - \min(x)) / (\max(x) - \min(x))$, onde: y são valores normalizados e x_i das polarizações VV/VH ou dos índices de vegetação.

Tabela 1. Índices de vegetação (IV) aplicados à banda C.

IV	Descrição	Fórmula
RVI	Radar vegetation index	$(VV/(VV+VH))^{0.5} * (4*VH/(VV+VH))$
RATIO	Proporção VH/VV	VH/VV
RFDI	Radar forest vegetation index	$VV-VH/VV+VH$

Fonte: Do autor (2024)

Nesta etapa conduziu-se o treinamento de modelos de Machine Learning aplicando três diferentes modelos, sendo *Random Forest* - RF (variação do nº de árvores e nós), *Support Vector Machine* - SVM (Radial, Polinomial, Regressão) e *Neural Networks* - NN (variação do nº de camadas).

A suficiência do intervalo de cobertura do dossel (cc) foi avaliada por meio de sua distribuição de frequência em um histograma. Para a modelagem, as bandas (VV e VH) do Sentinel-1 e os índices RVI, RATIO e RFDI, os mesmos passaram por um processo de seleção de variáveis com base na correlação de Spearman, utilizando um limite de 0,90 para eliminar redundâncias e colinearidade (Jiarpakdee et al., 2018).

As variáveis selecionadas alimentaram o modelo de *Random Forest* (RF), um algoritmo de aprendizado de máquina do tipo ensemble (Breiman, 2001). Os principais hiperparâmetros testados foram o número de variáveis por árvore ($mtry = 1, 2, 3$) e o número total de árvores ($ntree = 50, 100, 250, 500, 750$ e 1000), ajustados para otimizar o desempenho do modelo (Liaw; Wiener, 2002).


Além do RF, foi testada a *Support Vector Machine* (SVM), avaliando diferentes núcleos (kernels): linear, polinomial e radial. Por fim, a modelagem também incluiu a abordagem de *Neural Networks* (NN), explorando técnicas de aprendizado profundo com diferentes arquiteturas (32, 64 e 128 camadas), taxa de dropout de 50%, regularização de 0,001 e função de ativação ReLU, com saída sigmoidal (Goodfellow et al., 2016). Os modelos foram treinados em 50, 100 e 250 épocas.

O desempenho preditivo das abordagens foi comparado com base no erro médio absoluto (MAE) e na análise estatística das médias, utilizando o teste de ordenação em pares com correção de Bonferroni. O MAE foi escolhido por ser uma métrica robusta e de interpretação direta, expressando o erro médio em unidades reais da variável estimada, o MAE não penaliza excessivamente erros extremos, o que é desejável em dados SAR, onde o ruído speckle pode gerar outliers.

6 RESULTADOS

A figura 1 mostra a área usada para montar o conjunto de calibração dos modelos de predição de cobertura do dossel, combinando a imagem SAR Sentinel-1 (banda C) com os polígonos gerados pela segmentação do dossel. A distribuição homogênea dos segmentos indica que a segmentação conseguiu captar o padrão estrutural do talhão e suas variações internas de cobertura. Essa integração entre os dados SAR e a segmentação formou a base para gerar as amostras usadas no treinamento e na validação dos modelos de machine learning, assegurando que cada unidade analisada correspondesse à estrutura real da copa. Dessa forma, a figura sintetiza o suporte espacial da modelagem, unindo a capacidade do radar de diferenciar estruturas do dossel à eficiência da segmentação em extrair unidades consistentes para a calibração dos modelos.

Figura 1. Área de estudo para obtenção do dataset de calibração de modelos com a imagem SAR Sentinel-1 Banda C e segmentação do dossel (cc).




Fonte: Do autor (2024)

O resultado da correlação aplicada sobre as variáveis espectrais indica que, ao se aplicar um limiar de correlação de 0.90 com o método de Spearman, foram selecionadas três variáveis com menor colinearidade entre si: RVI, RATIO e RFDI. Essas três variáveis foram consideradas representativas e não redundantes dentro do conjunto analisado, sendo que a correlação mais alta remanescente entre elas foi de 0.707, abaixo do limite imposto. Os indicadores de multicolinearidade confirmam que, embora exista alguma correlação entre as variáveis, os valores de R^2 (< 0.74), Tolerance (> 0.26) e VIF (< 4) permanecem dentro de limites aceitáveis, sugerindo que as variáveis selecionadas são adequadas para uso conjunto em modelos estatísticos sem causar problemas sérios de redundância ou instabilidade nos coeficientes.

A figura 2 mostra que a maioria das áreas apresenta cobertura do dossel alta (entre 50% e 80%), mas há muitos pixels com cobertura nula, indicando presença significativa de áreas abertas ou solo exposto.

Figura 2. Distribuição da cobertura do dossel (%) pela segmentação do dossel por RGB em drone.



Fonte: Do autor (2024)

O desempenho de modelos de machine learning SVM, Random Forest e Redes Neurais testados na predição da cobertura do dossel vegetal com base nos índices RVI, RATIO e RFDI do Sentinel-1 na fase de treino foram comparados utilizando a métrica de erro médio absoluto (MAE) (Figura 3). Os modelos SVM (nas versões radial, polinomial e linear) apresentaram os menores valores de MAE, indicando maior precisão nas estimativas e sem diferença entre os mesmos. Esses modelos foram agrupados estatisticamente como grupo "c", o que reforça sua superioridade em relação às demais abordagens (Figura 3).


Os modelos Random Forest ocuparam uma posição intermediária, com desempenho estável e agrupados no grupo "b", enquanto as Redes Neurais apresentaram os maiores erros e foram classificadas no grupo "a", indicando desempenho significativamente inferior. Assim, os resultados evidenciam que, para essa base de dados e variáveis preditoras, as SVMs são mais eficazes, seguidas pelas Random Forests, e por fim, pelas Redes Neurais (Figura 3).

Os menores valores de erro médio absoluto (MAE) observados neste conjunto indicam que os modelos do tipo SVM, especialmente as variantes polynomial (0,2282) e radial (0,2286), apresentaram o melhor desempenho preditivo para estimar a cobertura do dossel a partir dos

índices derivados do Sentinel-1. Modelos Random Forest bem parametrizados, como o RF_100_2 e o RF_500_1, também aparecem entre os de melhor desempenho, com valores de MAE próximos a 0.2378. Isso mostra que, embora as SVMs liderem, os Random Forests não estão muito atrás em termos de precisão (Figura 3).

Por outro lado, os piores desempenhos são notoriamente associados às Redes Neurais (NN), com valores de MAE próximos a 0,4809, mais que o dobro dos melhores modelos. Os piores resultados incluem configurações como NN_32_50, NN_128_100 e NN_128_250, indicando que mesmo com diferentes combinações de camadas ocultas e épocas de treinamento, as redes neurais não conseguiram capturar bem a variabilidade do dossel a partir dos índices utilizados. Isso evidencia limitações no ajuste dessas redes ou a necessidade de reconfiguração e normalização dos dados de entrada (Figura 3).

Figura 3. Resultado do desempenho dos modelos de machine learning testados para a predição do dossel em função dos índices RVI, RATIO e RFDI do Sentinel-1.




Fonte: Do autor (2024)

A Figura 4 apresenta a área usada para validar o melhor modelo de predição da cobertura do dossel, integrando a imagem SAR Sentinel-1 (banda C) com a segmentação das copas. Sobre essa base, os segmentos do dossel aparecem como pontos ou pequenas manchas em preto, distribuídos de forma contínua ao longo do talhão destinado à validação. Essa distribuição indica que a segmentação também representou bem a estrutura da vegetação na área, independente do treinamento, condição essencial para avaliar corretamente o desempenho do modelo.


A sobreposição entre os segmentos e a resposta SAR permitiu comparar os valores de cobertura vegetal observados em campo (por drone) com a predita pela imagem de radar exibido na Figura 5, possibilitando o cálculo do erro médio absoluto (MAE). Nessa etapa, o SVM polinomial apresentou MAE de 0,2536655 muito próximo ao erro do treinamento (0,2282) demonstrando consistência e boa capacidade de generalização na predição da cobertura do dossel. Assim, a figura sintetiza o ambiente espacial de validação, evidenciando a relação entre estrutura real da vegetação, resposta SAR e segmentação, que sustentou a análise quantitativa do modelo.

Figura 4. Área de estudo para validação de melhor modelo com a imagem SAR Sentinel-1 Banda C e segmentação do dossel (cc).



Fonte: Do autor (2024)

Figura 5. Validação na área 2.



Fonte: Do autor (2024)

7 DISCUSSÃO

De acordo com Long et al., (2015) a segmentação semântica consiste em classificar cada pixel de uma imagem em categorias previamente definidas, permitindo assim a identificação dos diversos elementos que compõem uma floresta. No âmbito da silvicultura, essa técnica possibilitou a classificação detalhada de objetos presentes no solo e acima dele, como árvores e solo exposto. Por meio da aplicação da segmentação semântica, podemos criar mapas detalhados e precisos das áreas florestais (Figura 1), o que facilita o monitoramento das mudanças na vegetação, o estudo dos habitats da fauna, a avaliação da saúde das florestas e o desenvolvimento de práticas de manejo sustentável.

Os resultados da análise de observações realizadas utilizando o método de Spearman com um limiar rigoroso de 0,90 permitiram a seleção de três variáveis espectrais RVI, RATIO e RFDI que apresentam menor colinearidade entre si. Essa seleção cuidadosa é fundamental para evitar redundância em modelos estatísticos, garantindo que as variáveis incluídas sejam representativas e independentes o suficiente para contribuir com informação única ao modelo (Dormann et al., 2013). A correlação mais alta observada entre essas variáveis (0,707) está abaixo do limite estabelecido, estabelecendo uma associação moderada que não compromete a

individualidade das variáveis, conforme recomendado na literatura para minimizar os efeitos negativos da colinearidade (Midi et al., 2010).

Adicionalmente, os indicadores clássicos de multicolinearidade corroboram a adequação das variáveis escolhidas. Os valores de R^2 inferiores a 0,74, tolerância acima de 0,26 e o índice VIF abaixo de 4 estão dentro dos parâmetros considerados seguros para a construção de modelos robustos (O'Brien, 2007). Esses índices sugerem que, apesar da existência de alguma evidência entre as variáveis, não há um risco elevado de instabilidade nos coeficientes das variáveis devido à redundância, o que é crucial para a confiabilidade das inferências realizadas (Kutner et al., 2005).

Em suma, a combinação de uma seleção com a validação por meio de múltiplos indicadores de multicolinearidade reforça que as variáveis RVI, RATIO e RFDI são específicas para uso conjunto em análises estatísticas. Essa abordagem contribui para a construção de modelos mais interpretáveis e com menor risco de viés decorrente de variáveis altamente correlacionadas, alinhando-se às boas práticas recomendadas em análises multivariadas.

A distribuição da cobertura do dossel observada no histograma reflete tanto a estrutura esperada de um plantio de eucalipto de idade uniforme quanto os efeitos diretos das áreas afetadas pelo ataque de formigas-cortadeiras. O uso de imagens de altíssima resolução espacial (3 cm/pixel) amplia a capacidade de identificar essas alterações, revelando padrões de desfolha que dificilmente seriam detectados por sensores orbitais de média ou baixa resolução (Fassnacht et al., 2016).

O pico de valores próximos a 0% de cobertura pode estar associado não apenas a clareiras operacionais e falhas de plantio, mas também a áreas extremamente desfolhadas, onde a copa foi parcialmente ou totalmente removida. Nessas situações, a área foliar reduzida expõe o solo, produzindo pixels com valores extremamente baixos de cobertura. Como o ataque das formigas costuma ocorrer de forma agregada (Zanetti et al., 2014), agrupamentos de pixels muito baixos podem indicar focos ativos ou áreas críticas em processo de expansão.

A maior concentração de valores entre 60% e 85% representam regiões que permanecem estruturalmente preservadas, com copas bem formadas e pouca influência de pragas. Em plantios homogêneos, é comum observar esse padrão em idades intermediárias, e a uniformidade registrada sugere que grande parte da área mantém bom estado fisiológico (Stape et al., 2010). Ainda assim, pequenas oscilações dentro desse intervalo podem sinalizar desfolhas moderadas, típicas de ataques iniciais ou recorrências de baixa intensidade.

Os valores intermediários (10–50%) merecem atenção especial no contexto de pragas. Esse intervalo costuma representar áreas parcialmente desfolhadas, onde o ataque reduziu o vigor das copas, mas não resultou na remoção completa da folhagem. A resolução de 3 cm permite visualizar lacunas na copa, aberturas entre galhos e mudanças no formato das árvores, o que facilita a identificação de sinais precoces de herbivoria (Back et al., 2025). Por isso, esse conjunto intermediário pode funcionar como um indicador de transição entre áreas saudáveis e regiões com danos severos, auxiliando na definição de zonas prioritárias para manejo.

Além dos efeitos imediatos, a desfolha provocada pelas formigas altera a estrutura do plantio ao longo do tempo. A perda de folhas reduz o crescimento, aumenta a vulnerabilidade a outros estresses bióticos e abióticos e modifica o ritmo de fechamento do dossel, contribuindo para maior heterogeneidade estrutural (Elek; Baker, 2017). Essa variabilidade aparece diretamente no histograma e reforça a importância do sensoriamento remoto de altíssima resolução para captar tais nuances.

Em conjunto, o histograma evidencia que a estrutura do dossel em plantios de eucalipto é profundamente influenciada pelo ataque de formigas-cortadeiras, que gera desde pequenas aberturas até áreas totalmente desfolhadas. A integração entre imagens de 3 cm e análise espacial da cobertura do dossel oferece uma leitura precisa dos impactos da praga, permitindo diagnóstico precoce, direcionamento eficiente das ações de manejo e avaliação da eficácia das medidas de controle. Esses resultados reforçam o potencial da abordagem para programas modernos de monitoramento florestal e Manejo Integrado de Pragas (MIP) em plantios comerciais.

Os resultados deste estudo mostram diferenças claras no desempenho dos modelos de machine learning usados para estimar a cobertura do dossel a partir dos índices SAR RVI, RATIO e RFDI e as bandas (VV e VH) derivados do Sentinel-1. Como o objetivo central da pesquisa é monitorar a desfolha causada por formigas-cortadeiras em plantios de eucalipto, avaliar a acurácia dos modelos torna-se essencial. Esse tipo de dano gera alterações estruturais discretas na copa como perda de biomassa foliar, redução da rugosidade e mudanças na umidade que podem ser detectadas pelo radar.

O Erro Médio Absoluto (MAE) foi uma métrica adequada para quantificar a precisão das estimativas, e o teste estatístico com correção de Bonferroni permitiu ordenar os modelos de maneira consistente. As Redes Neurais apresentaram o pior desempenho, formando o grupo “a”, com MAE’s acima de 0,40. Esse resultado não surpreende, já que diversos estudos mostram

que redes neurais exigem grandes volumes de dados, ajustes complexos e arquiteturas específicas para captar padrões delicados do espalhamento SAR, sobretudo quando se trata de variações sutis na estrutura do dossel (Sinha et al., 2019). Além disso, a sensibilidade dessas redes ao ruído e à redundância das variáveis de radar contribui para o desempenho inferior, algo já registrado em pesquisas sobre distúrbios florestais.

O Random Forest apresentou resultados intermediários (grupo “b”), valores de MAE próximos a 0.2378. Essa estabilidade já era esperada, pois o algoritmo é reconhecido por lidar bem com variáveis correlacionadas, ruído speckle e a complexidade estrutural típica de dados SAR (Belgiu; Drăguț, 2016). A literatura destaca inclusive que o RF é amplamente empregado em estudos florestais com radar, especialmente em estimativas de biomassa e carbono. Porém, embora robusto, o RF não tem a mesma sensibilidade de métodos baseados em margens de separação para capturar pequenas alterações na copa, como as provocadas por desfolha parcial.

A melhor performance foi obtida pelas Support Vector Machines (SVM), classificadas no grupo “c”, especialmente as variantes polynomial (0,2282) e radial (0,2286). Esse resultado está alinhado com estudos que destacam a eficiência das SVMs em dados SAR, sobretudo quando o conjunto de atributos é compacto e sujeito a ruídos cenário típico dos índices RFDI e RVI. A boa capacidade do kernel radial em lidar com padrões não lineares ajuda a explicar esse desempenho superior, considerando que o espalhamento radar na vegetação é fortemente influenciado por parâmetros estruturais como densidade foliar, umidade e organização volumétrica da copa, todos afetados pela ação das formigas-cortadeiras (Santos et al., 2022).

A literatura também reforça que o Sentinel-1 é sensível a alterações estruturais e perda de folhagem, tanto em florestas naturais quanto em plantações. No caso específico do eucalipto, estudos que combinam machine learning e imagens de alta resolução têm alcançado bons resultados na identificação de manchas de desfolha, validando o uso conjunto de algoritmos e variáveis de sensoriamento remoto no diagnóstico de danos causados por pragas.

Comparações com trabalhos internacionais reforçam essa tendência. Em Pu’er, na China, a combinação de dados SAR, ópticos e texturais apresentou alta sensibilidade para estimar biomassa aérea, com métodos como RF e Support Vector Regression obtendo resultados consistentes (Wang et al., 2025). Embora o XGBoost tenha se destacado nesse estudo, o bom desempenho de modelos baseados em kernel confirma que informações estruturais derivadas do radar são valiosas para estimar características vinculadas ao dossel, o que vai ao encontro da abordagem empregada aqui.

Outros trabalhos mostram que classificadores como SVM e RF costumam superar métodos tradicionais na discriminação de cobertura florestal em dados SAR (Lapini et al., 2020), reforçando que as escolhas metodológicas deste estudo estão alinhadas ao estado da arte.

Apesar disso, a literatura também aponta limitações do uso isolado do radar. Ferla, Kuplich e Narvaes (2023) verificaram menor acurácia ao classificar uso e cobertura apenas com variáveis SAR, quando comparado à combinação com dados ópticos. Essa constatação abre caminhos promissores para estudos futuros, como a fusão de dados Sentinel-1 e Sentinel-2 ou a incorporação de texturas multiespectrais, ampliando a capacidade de detectar desfolhas mais sutis.

Além disso, pesquisas recentes mostram que modelos de deep learning aplicados a séries temporais especialmente redes recorrentes podem superar SVM e RF em alguns cenários de monitoramento da vegetação (Minh et al., 2017). Embora as RNAs testadas aqui não tenham apresentado bom desempenho, há potencial de melhoria com a inclusão de séries temporais completas, já que a desfolha provoca mudanças contínuas e detectáveis ao longo do tempo no backscatter.

Os resultados obtidos a partir da área de validação e o predito pelo modelo na Figura 5 mostra com clareza a boa capacidade dos dados SAR do Sentinel-1 em estimar a cobertura vegetal em plantios de eucalipto. Mesmo trabalhando com resolução de 10 m, o sensor conseguiu reproduzir de maneira consistente os padrões espaciais do dossel observados na verdade de campo obtida por drone, com resolução muito superior (3 cm/pixel). Essa correspondência visual é confirmada pelos resultados quantitativos: o erro médio absoluto (MAE) na área de validação foi de 0,2536655 para o modelo SVM polinomial, muito próximo ao erro obtido no treino (0,2282). A proximidade entre esses valores indica estabilidade do modelo, baixa tendência ao sobreajuste e boa capacidade de generalização.

O desempenho consistente demonstra que os índices derivados do SAR (RVI, RATIO e RFDI), quando combinados a algoritmos de aprendizado de máquina, conseguem captar de maneira adequada variações estruturais do dossel, permitindo estimativas confiáveis de cobertura foliar. Na imagem predita, é possível observar gradientes contínuos de densidade do dossel, o que mostra que o modelo traduziu diferenças sutis no retorno de micro-ondas em valores interpretáveis biologicamente.

Esse comportamento também está em acordo com o que a literatura descreve para sensores SAR, especialmente na banda C. Diversos estudos mostram que esse tipo de dado é

sensível à rugosidade, ao volume e à densidade foliar da vegetação (Lausch et al., 2016; dos Santos et al., 2021). Mesmo com resolução espacial moderada, sensores como o Sentinel-1 conseguem registrar alterações estruturais associadas a fatores bióticos, incluindo herbivoria, estresse e perda foliar em diferentes intensidades.

A herbivoria desse grupo pode modificar significativamente a estrutura da copa, reduzir biomassa foliar e alterar a rugosidade superficial das árvores características diretamente relacionadas à resposta SAR (Santos et al., 2022). A boa performance do modelo reforça, portanto, que o radar pode detectar indiretamente esses distúrbios, por meio das mudanças estruturais que eles provocam no dossel.

A combinação entre baixo erro, consistência entre treino e validação e coerência espacial nas estimativas confirma que os dados do Sentinel-1 são preditores sólidos e eficientes para o monitoramento operacional da cobertura vegetal. Além disso, a independência em relação às condições atmosféricas e a alta frequência de revisita tornam o radar uma ferramenta estratégica para programas contínuos de manejo e acompanhamento da sanidade florestal.

Por fim, estudos sobre monitoramento de infestações de pragas e mudanças graduais na vegetação apontam que o sensoriamento remoto é eficiente mesmo diante de alterações discretas, situação muito semelhante à desfolha causada por formigas-cortadeiras. Esses achados indicam que as técnicas avaliadas têm grande potencial para serem incorporadas a sistemas operacionais de Manejo Integrado de Pragas no setor florestal.

8 CONCLUSÃO

Os resultados deste estudo mostram que a combinação de dados SAR do Sentinel-1 com índices derivados (RVI, RATIO e RFDI) e métodos de aprendizado de máquina é eficaz para estimar a cobertura do dossel em plantios de eucalipto atacados por formigas-cortadeiras. A seleção das variáveis, conduzida com base em critérios rigorosos de correlação e multicolinearidade, garantiu o uso de preditores independentes e adequados às análises, contribuindo para a estabilidade dos modelos construídos.

A avaliação estrutural do dossel, obtida a partir de imagens de altíssima resolução, evidenciou a relação direta entre os níveis de cobertura e diferentes graus de desfolha, o que confirma a sensibilidade do método para identificar alterações provocadas pela desfolha causada pelas formigas cortadeiras. Entre os algoritmos testados, as *Support Vector Machines*, especialmente com kernels polinomial e radial, apresentaram o melhor desempenho, com erros

reduzidos e boa concordância entre os resultados de treino e validação. Esses achados reforçam a adequação das SVMs para lidar com padrões complexos e sujeitos a ruído, como os provenientes do radar.

A validação espacial mostrou correspondência clara entre a cobertura observada por drone (3 cm/pixel) e as estimativas do Sentinel-1 (10 m/pixel). Mesmo com resolução mais baixa, o sensor foi capaz de representar variações estruturais associadas à perda de biomassa foliar. Além disso, sua independência das condições atmosféricas e a alta frequência de revisita o tornam adequado para aplicações operacionais de monitoramento florestal.

Os resultados obtidos dialogam com pesquisas já consolidadas na área e demonstram que a abordagem testada é tecnicamente sólida e aplicável ao diagnóstico de danos em escala operacional. Estudos futuros podem avançar no uso de séries temporais completas, na integração de dados ópticos e SAR e na aplicação de arquiteturas de deep learning, ampliando a capacidade de detectar desfolhas mais sutis.

Por conseguinte, o trabalho confirma que dados SAR associados a modelos de aprendizado de máquina constituem uma ferramenta precisa e funcional para identificar e quantificar a desfolha causada por formigas-cortadeiras, oferecendo suporte relevante às estratégias de monitoramento florestal e ao Manejo Integrado de Pragas.

REFERÊNCIAS

- ABDI, A. M. et al. Satellite Remote Sensing of Savannas: Current Status and Emerging 3 Opportunities. *Journal of Remote Sensing*, v. 2022, 2 nov. 2022. doi: 4 <https://doi.org/10.34133/2022/9835284>
- ABDOLLAHNEJAD, A.; PANAGIOTIDIS, D. Tree species classification and health status assessment for mixed broadleaf–conifer forest with UAS multispectral imaging. *Remote Sensing*, v. 12, 3722, 2020.
- ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. *Remote Sensing*, v. 11, 1373, 2019.
- AHMAD, U.; ALVINO, A.; MARINO, S. A review of crop water stress assessment using remote sensing. *Remote Sensing*, v. 13, 4155, 2021.
- ALÍPIO, A. S. Controle de formigas cortadeiras. *Normas Técnicas da Pains Florestal*, 1989. 8 p.
- AMPATZIDIS, Y.; PARTEL, V.; MEYERING, B.; ALBRECHT, U. Citrus rootstock evaluation utilizing UAV-based remote sensing and artificial intelligence. *Computers and Electronics in Agriculture*, v. 164, 2019.
- ANJOS, N.; DELLA-LUCIA, T. M. C.; MAYHÉ-NUNES, A. J. Guia prático sobre formigas cortadeiras em reflorestamentos. Ponte Nova: Graff Cor, 1998. 100 p.
- ANJOS, N.; MOREIRA, D. D. O.; DELLA LUCIA, T. M. C. Manejo integrado de formigas cortadeiras em reflorestamentos. In: DELLA LUCIA, T. M. C. (org.). *As formigas cortadeiras*. Viçosa: UFV, 1993. p. 212–241.
- ARENAS-CASTRO, S.; FERNÁNDEZ-HAEGER, J.; JORDANO, D. Evaluation and comparison of QuickBird and ADS40-SH52 multispectral imagery for mapping Iberian wild pear trees (*Pyrus bourgaeana*, Decne) in a Mediterranean mixed forest. *Forests*, v. 5, p. 1304–1330, 2014.
- ARIAS, M.; CAMPO-BESCÓS, M. Á.; ÁLVAREZ-MOZOS, J. Crop Classification Based 10 on Temporal Signatures of Sentinel-1 Observations over Navarre Province, Spain. *Remote 11 Sensing*, v. 12, n. 2, 2020. doi: <https://doi.org/10.3390/rs12020278>
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. *International 14 Journal of Remote Sensing*, v. 22, n. 18, p. 3855–3862, 1 jan. 2001. doi: 15 <https://doi.org/10.1080/01431160010006926>
- BACK, H. M.; PÉREZ-POSTIGO, I.; GEITNER, C.; ARNETH, A. Analysing the impact of large mammal herbivores on vegetation structure in Eastern African savannas combining high spatial resolution multispectral remote sensing data and field observations. *Ecological Informatics*, v. 87, p. 103113, 2025. doi: <https://doi.org/10.1016/j.ecoinf.2025.103113>

- BADRELDIN, N.; SANCHEZ-AZOFEIFA, A. Estimating Forest biomass dynamics by integrating multitemporal Landsat satellite images with terrestrial and airborne LiDAR data at the Coal Valley Mine, Alberta, Canada. *Remote Sensing*, v. 7, p. 2832–2849, 2015.
- BALLESTEROS, R.; ORTEGA, J. F.; HERNÁNDEZ, D.; MORENO, M. A. Applications of georeferenced high-resolution images obtained with unmanned aerial vehicles. Part I: Description of image acquisition and processing. *Precision Agriculture*, v. 15, p. 579–592, 2014.
- BANSKOTA, A. et al. Forest monitoring using Landsat time series data: A review. *Canadian Journal of Remote Sensing*, v. 40, p. 362–384, 2014.
- BELGIU, M.; DRĂGUT, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24–31, 2016.
- BELOIU, M. et al. Individual tree-crown detection and species identification in heterogeneous forests using aerial RGB imagery and deep learning. *Remote Sensing*, v. 15, 1463, 2023.
- BOATENG, E. Y.; OTOO, J.; ABAYE, D. A. Basic tenets of classification algorithms k-nearest-neighbor, support vector machine, random forest and neural network: A review. *Journal of Data Analysis and Information Processing*, v. 8, p. 341–357, 2020.
- BOUSBIH, S. et al. Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal 21 Cover Parameters. *Sensors*, v. 17, n. 11, 2017. doi: <https://doi.org/10.3390/s17112617>
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, p. 5–32, 2001.
- BRODRICK, P. G.; DAVIES, A. B.; ASNER, G. P. Uncovering ecological patterns with convolutional neural networks. *Trends in Ecology & Evolution*, v. 34, p. 734–745, 2019.
- CANTARELLI, E. B. et al. Plano de amostragem de *Acromyrmex* spp. (Hymenoptera: 31 Formicidae) em áreas de pré-plantio de *Pinus* spp. *Ciência Rural*, v. 36, n. 2, p. 385–390, 32 mar. 2006. doi: <https://doi.org/10.1590/S0103-84782006000200005>
- CAMARGO, F. F. et al. A Comparative Assessment of Machine-Learning Techniques for 26 Land Use and Land Cover Classification of the Brazilian Tropical Savanna Using ALOS-27 2/PALSAR-2 Polarimetric Images. *Remote Sensing*, v. 11, n. 13, 2019. doi: 28 <https://doi.org/10.3390/rs11131600>
- CAMARRETTA, N. et al. Monitoring forest structure to inform adaptive forest restoration management: A review of remote sensing approaches. *New Forests*, v. 51, p. 573–596, 2020.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to Remote Sensing*. New York: Guilford Press, 2011.
- CAVENDER-BARES, J. et al. Integrating remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology & Evolution*, v. 6, p. 506–519, 2022.

- CECCATO, P. et al. Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, v. 77, p. 22–33, 2001.
- CHAMPION, I.; DA COSTA, J.P.; GODINEAU, A.; VILLARD, L.; DUBOIS-FERNANDEZ, P.; LE TOAN, T. Canopy structure effect on SAR image texture versus forest biomass relationships. *EARSeL eProceedings*, v. 12, n. 1, p. 25-32, 2013. doi: <https://doi.org/10.12760/01-2013-1-03>
- CHANDER, G.; HAQUE, M. O.; MICIJEVIC, E.; BARSI, J. A. A procedure for radiometric recalibration of the Landsat 5 TM reflective-band data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, p. 556–574, 2010.
- CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric Radar Vegetation Index for biomass estimation in desert fringe ecosystems. *IEEE Transactions on Geoscience and Remote Sensing*, v. 56, p. 7102–7108, 2018.
- CHATZIANTONIOU, A.; PSOMIADIS, E.; PETROPOULOS, G. P. Co-Orbital Sentinel 1 35 and 2 for LULC Mapping with Emphasis on Wetlands in a Mediterranean Setting Based on 36 Machine Learning. *Remote Sensing*, v. 9, n. 12, 2017. doi: <https://doi.org/10.3390/rs9121259>
- CHEHREH, B.; MOUTINHO, A.; VIEGAS, C. Latest trends on tree classification and segmentation using UAV data—A review of agroforestry applications. *Remote Sensing*, v. 15, 2263, 2023.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels 39 with machine learning methods at Sentinel-2 MSI spectral resolutions. *Precision Agriculture*, v. 18, n. 5, p. 859–881, 2017. doi: <https://doi.org/10.1007/s11119-016-9495-0>
- CHOLLET, F.; ALLAIRE, J.J. *Deep Learning with R*. 1 ed. Shelter Island: Mannig 43 Publication Co. 335p. 2018.
- CLAY, D. et al. Characterizing water and nitrogen stress in corn using remote sensing. *Agronomy Journal*, v. 98, p. 579–587, 2006.
- CLEVERS, J. G. P. W.; KOOISTRA, L.; DEN BRANDE, M. M. M. Using Sentinel-2 Data 46 for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop. *Remote Sensing*, v. 9, n. 5, 2017. doi: <https://doi.org/10.3390/rs9050405>
- COHEN, W. B. et al. Diversity of algorithm and spectral band inputs improves Landsat monitoring of forest disturbance. *Remote Sensing*, v. 12, 1673, 2020.
- CROSTA, A. P. *Processamento digital de imagens de sensoriamento remoto*. UNICAMP/Instituto de Geociências, 1999. Disponível em: <https://encurtador.com.br/afDSW>. Acesso em: 20 jun. 2023.
- CSORBA, A.; SZEGI, T.; FODOR, H.; BUKOMBE, B.; UWIRAGIYE, Y.; ARAMABUYE, F. X.; MICHÉLI, E. Characterization of rice agriculture in the Southern 1 Province of Rwanda by means of microwave remote sensing. *Physics and Chemistry of the Earth, Parts A/B/C*, v. 112, p. 58-65, 2019. doi: <https://doi.org/10.1016/j.pce.2019.02.002>

CURRAN, P. J.; DUNGAN, J. L.; GHOLZ, H. L. Exploring the relationship between reflectance red edge and chlorophyll content in slash pine. *Tree Physiology*, v. 7, p. 33–48, 1990.

ÇOBAN, O.; OZCELIK, R.; AVCI, M. Monitoring of damage from cedar shoot moth 5 *Dichelia cedricola* Diakonoff (Lep.: Tortricidae) by multi-temporal Landsat imagery. *iForest 6 - Biogeosciences and Forestry*, n. 2, p. 126–131, 2014. doi: https://doi.org/10.3832/ifor1014-7_007

DASH, J. P.; PEARSE, G. D.; WATT, M. S. UAV Multispectral Imagery Can Complement 10 Satellite Data for Monitoring Forest Health. *Remote Sensing*, v. 10, n. 8, 2018. doi: <https://doi.org/10.3390/rs10081216> DE LIMA, R. A. F. et al. Making forest data FAIR and open. *Nature Ecology & Evolution*, v. 6, p. 656–658, 2022.

DELLA LUCIA, T. M.; GANDRA, L. C.; GUEDES, R. N. Managing leaf-cutting ants: 14 peculiarities, trends and challenges. *Pest Management Science*, v. 70, n. 1, p. 14–23, jan. 15 2014. doi: <https://doi.org/10.1002/ps.3660>

DEL-CAMPO-SANCHEZ, A. et al. Geometric characterization of vines from 3D point clouds obtained with laser scanner systems. *Remote Sensing*, v. 11, 2365, 2019.

DONG, Y.; XU, F.; LIU, L. Monitoring and forecasting for disease and pest in crop based on WebGIS system. In: *Proceedings of the 8th International Conference on Agro-Geoinformatics*. IEEE, 2019. p. 1–5. DOI: [10.1109/Agro-Geoinformatics.2019.8820620](https://doi.org/10.1109/Agro-Geoinformatics.2019.8820620)

DORMANN, C. F. et al. Collinearity: A review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, v. 36, n. 1, p. 27–46, 2013.

DOS SANTOS, E. P. et al. Vegetation cover monitoring in tropical regions using SAR-C dual-polarization index. *International Journal of Remote Sensing*, v. 42, p. 7581–7609, 2021.

DOS SANTOS, E. P.; DA SILVA, D. D.; DO AMARAL, C. H. Vegetation cover monitoring in tropical regions using SAR-C dual-polarization index: Seasonal and spatial influences. *International Journal of Remote Sensing*, v. 42, p. 7581–7609, 2021.

DU, Y. et al. Water Bodies' Mapping from Sentinel-2 Imagery with Modified Normalized 18 Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band. *Remote Sensing*, v. 8, n. 4, 2016. doi: <https://doi.org/10.3390/rs8040354>

DUSSEUX, P.; CORPETTI, T.; HUBERT-MOY, L.; CORGNE, S. Combined use of multi-22 temporal optical and radar satellite images for grassland monitoring. *Remote Sensing*, v. 6, n. 23 7, p. 6163–6182, 2014. doi: <https://doi.org/10.3390/rs6076163>

EBRAHIMI, M. A.; KHOSHTAGHAZA, M. H.; MINAEI, S. Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, v. 137, p. 52–58, 2017.

ELEK, J. A.; BAKER, S. C. Timing and frequency are the critical factors affecting the impact of defoliation on long term growth of plantation eucalypts. *Forest Ecology and Management*, v. 391, p. 1–8, 2017. doi: <https://doi.org/10.1016/j.foreco.2017.02.004>

ESA. Sentinel-1 User Handbook. ESA User Guide. Paris: ESA, 2013.

ESA. Sentinel-2 User Handbook. ESA Standard Document. Paris: ESA, 2015.

EUROPEAN SPACE AGENCY. Sentinel-1 SAR technical guide. 2018 Disponível em: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar>. Acesso em: 27 01 jun. 2023.

FAO. NSP–Integrated Pest Management. 2020.

FASSNACHT, F.E.; LATIFI, H.; STERENĆZAK, K.; MODZELEWSKA, A.; LEFSKY, M.; WASER, L.T.; STRAUB, C.; GHOSH, A. Review of studies on tree species classification from remotely sensed data. *Remote sensing of environment*, v. 186, p. 64-87, 2016. doi: <https://doi.org/10.1016/j.rse.2016.08.013>

FERLA, A. K.; KUPLICH, T. M.; NARVAES, I. da S. Utilização do classificador Random Forest para classificação do uso e cobertura da terra a partir de dados Sentinel-1 e Sentinel-2 em região campestre no bioma Mata Atlântica. *Geografia: Ensino & Pesquisa*, v. 29, e87967, 2025.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. *30 Ciência da Informação*, v. 35, n. 1, p. 25–30, jan. 2006. doi: <https://doi.org/10.1590/S0100-3119652006000100003>

FERREIRA, F. A. Patologia florestal: principais doenças florestais no Brasil. Viçosa: Sociedade de Investigações Florestais, 1989. 570 p.

FLEET, D. J. Example segmentations: Simple scenes. 2007. p. 1–34.

FREITAS, S.; BERTI FILHO, E. Efeito do desfolhamento no crescimento de *Eucalyptus 39 grandis* hill ex maiden (myrtaceae). IPEF, 1994.

FOREST STEWARDSHIP COUNCIL - FSC. List of approved derogations for use of ‘highly 34 hazardous’ pesticides. FSC-PRO-30-001a EN. Disponível em: ; 36 Acesso em: 15 de out. de 2023.

GAUSMAN, H. W. Reflectance of leaf components. *Remote Sensing of Environment*, v. 6, p. 1–9, 1977.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. Cambridge: MIT Press, 2016.

GOVENDER, M. et al. Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water SA*, v. 35, p. 741–752, 2009.

HAGENSIEKER, R.; WASKE, B. Evaluation of multi-frequency SAR images for tropical land cover mapping. *Remote Sensing*, v. 10, n. 2, p. 257, 2018. doi: <https://doi.org/10.3390/rs10020257>

- HALL, R.J.; SKAKUN, R.S.; ARSENAULT, E.J.; CASE, B.S. Modeling forest stand structure attributes using Landsat ETM+ data: Application to mapping of aboveground biomass and stand volume. *Forest ecology and management*, v. 225, n. 1-3, p. 378-390, 2006. doi: <https://doi.org/10.1016/j.foreco.2006.01.014>
- HALL, O.; OHLSSON, M.; RÖGNVALDSSON, T. A review of explainable AI in the satellite data, deep machine learning and human poverty domain. *Patterns*, v. 3, 100600, 2022.
- HARRIS, A.; BRYANT, R. G.; BAIRD, A. J. Mapping the effects of water stress on Sphagnum: Preliminary observations using airborne remote sensing. *Remote Sensing of Environment*, v. 100, p. 363–378, 2006.
- HAUGLIN, M.; ØRKA, H. O. Discriminating between native Norway spruce and invasive Sitka spruce: A comparison of multitemporal Landsat 8 imagery, aerial images and airborne laser scanner data. *Remote Sensing*, v. 8, 363, 2016.
- HERNÁNDEZ, J. V.; JAFFÉ, K. Dano econômico causado por populações de formigas *Atta 42 laevigata* (F. Smith) em plantações de *Pinus caribaea* Mor. e elementos para o manejo da 43 praga. *Anais da Sociedade Entomológica do Brasil*, v. 24, n. 2, p. 287-298, 1995. doi: <http://dx.doi.org/10.37486/0301-8059.v24i2.1029>.
- HILL, R. A. et al. Mapping tree species in temperate deciduous woodland using time-series multispectral data. *Applied Vegetation Science*, v. 13, p. 86–99, 2010.
- HOLZINGER, A. et al. Digital transformation in smart farm and forest operations needs human-centered AI: Challenges and future directions. *Sensors*, v. 22, 3043, 2022.
- HU, G. et al. Long-term seasonal forecasting of a major migrant insect pest: the brown planthopper in the Lower Yangtze River Valley. *Journal of Pest Science*, v. 92, p. 417–428, 2019.
- HUANG, Z.; ZHANG, Y. Remote sensing of spruce budworm defoliation using EO-1 47 Hyperion hyperspectral data: an example in Quebec, Canada. *IOP Conference Series: Earth and Environmental Science*, v. 34, n. 1, p. 12017, abr. 2016. doi: <https://doi.org/10.1088/1755-1315/34/1/012017>
- HUETE, A. R. Remote sensing for environmental monitoring. In: ARTIOLA, J. F.; PEPPER, I. L.; BRUSSEAU, M. L. (eds.). *Environmental Monitoring and Characterization*. Cambridge: Academic Press, 2004. p. 183–206.
- HUNT, E. R. et al. Insect detection and nitrogen management for irrigated potatoes using remote sensing from small unmanned aircraft systems. In: *SPIE Commercial and Scientific Sensing and Imaging*, Baltimore, 17–21 Apr. 2016. 98660N.
- IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES. Relatório 2024. São Paulo, 2024. Acesso em: 10 out. 2025. Disponível em: <https://iba.org/wp-content/uploads/2025/05/relatorio2024.pdf>
- ISERING, R.; NEUMEISTER, L. Recommendations regarding derogations to use alpha-cypermethrin, deltamethrin, fenitrothion, fipronil and sulfluramdi in FSC Certified forests in

Brazil. In: FSC PESTICIDES COMMITTEE. Insecticides for control of pest insects in FSC Certified Forests in Brazil: recommendations by technical advisors. 2010. 99 p.

JAIN, P. et al. A review of machine learning applications in wildfire science and management. *Environmental Reviews*, v. 28, p. 478–505, 2020.

Ji, L. et al. Estimating aboveground biomass in interior Alaska with Landsat data and field measurements. *International Journal of Applied Earth Observation and Geoinformation*, v. 18, p. 451–461, 2012. doi: <https://doi.org/10.1016/j.jag.2012.03.019>

JIARPAKDEE, J.; TANTITHAMTHAVORN, C.; TREUDE, C. Autospearman: Automatically mitigating correlated software metrics for interpreting defect models. 2018.

JONES, H. G.; SCHOFIELD, P. Thermal and other remote sensing on plant stress. *General and Applied Plant Physiology*, v. 34, n. 1-2, p. 19–32, 2008.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. *Science*, v. 349, p. 255–260, 2015.

JORGE, L. D. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (Ed.). *Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa, 2014. p. 109–134. Disponível em: <https://anaisonline.uems.br/index.php/ecaeco/article/view/2832>. Acesso em: 20 jun. 2023.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. Review on convolutional neural networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 173, p. 24–49, 2021.

KELES, S. Optimal rotation ages in hybrid poplar plantations including carbon sequestration: A case study in Turkey. *Environmental Science and Forestry Series*, v. 22, p. 339–349, 2016.

KIM, Y.; VAN ZYL, J. J. A Time-Series Approach to Estimate Soil Moisture Using Polarimetric Radar Data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 8, p. 2519–2527, 2009.

KIM, Y.; VAN ZYL, J. On the relationship between polarimetric parameters. In: *IGARSS 2000 – IEEE International Geoscience and Remote Sensing Symposium*, Honolulu, 24–28 July 2000. Proceedings... New York: IEEE, 2000. v. 3, p. 1298–1300.

KROFCHECK, D. J. et al. Woody biomass estimation in a juniper savanna using lidar-derived clumped tree segmentation and existing allometries. *Remote Sensing*, v. 8, 453, 2016.

KUCK, T. N.; SANO, E. E.; BISPO, P. D. C.; SHIGUEMORI, E. H.; SILVA FILHO, P. F. F.; MATRICARDI, E. A. T. A comparative assessment of machine-learning techniques for forest degradation caused by selective logging in an Amazon region using multitemporal X-band SAR images. *Remote Sensing*, v. 13, n. 17, 3341, 2021.

KUMAR, P. et al. Estimation of winter wheat crop growth parameters using time series Sentinel-1A SAR data. *Geocarto International*, v. 33, n. 9, p. 942–956, 2018.

- KUSSUL, N. et al. Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 9, n. 6, p. 2500–2508, 2016.
- KUTNER, M. H.; NACHTSHEIM, C. J.; NETER, J.; LI, W. *Applied Linear Statistical Models*. New York: McGraw-Hill Irwin, 2005.
- KYCKO, M. et al. The impact of tourist traffic on the condition and cell structures of alpine swards. *Remote Sensing*, v. 10, 220, 2018.
- LANGFORD, Z. L. et al. Arctic vegetation mapping using unsupervised training datasets and convolutional neural networks. *Remote Sensing*, v. 11, n. 1, p. 69, 2019.
- LAPINI, A. et al. Comparison of machine learning methods applied to SAR images for forest classification in Mediterranean areas. *Remote Sensing*, v. 12, n. 3, 369, 2020.
- LAUSCH, A. et al. Understanding forest health with remote sensing – Part I: A review of spectral traits, processes and remote-sensing characteristics. *Remote Sensing*, v. 8, n. 12, 1029, 2016.
- LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. Applications in remote sensing to forest ecology and management. *One Earth*, v. 2, p. 405–412, 2020.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436–444, 2015.
- LEE, W. S. et al. Sensing technologies for precision specialty crop production. *Computers and Electronics in Agriculture*, v. 74, p. 2–33, 2010.
- LEWIS, T.; NORTON, G. An aerial baiting to control leaf-cutting ants (Formicidae: Attini) in Trinidad. *Bulletin of Entomological Research*, v. 63, p. 289–303, 1973.
- LI, M.; IM, J.; BEIER, C. Machine learning approaches for forest classification and change analysis using multi-temporal Landsat TM images over Huntington Wildlife Forest. *GIScience & Remote Sensing*, v. 50, p. 361–384, 2013.
- LI, R.; WANG, R.; ZHANG, J. An effective data augmentation strategy for CNN-based pest localization and recognition in the field. *IEEE Access*, v. 7, p. 160274–160283, 2019. DOI: 10.1109/ACCESS.2019.2949852
- LIAW, A.; WIENER, M. Classification and regression by randomForest. *R News*, v. 2, n. 3, p. 18–22, 2002. Acesso em: 20 jun. 2023.
- LIU, N. et al. Thermal remote sensing of plant water stress in natural ecosystems. *Forest Ecology and Management*, v. 476, 2020.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 7–12 June 2015. p. 3431–3440. Acesso em: 7 dez. 2025.

LU, D.; MAUSEL, P.; BRONDÍZIO, E.; MORAN, E. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. *Forest ecology and management*, v. 198, n. 1-3, p. 149-167, 2004. doi: <https://doi.org/10.1016/j.foreco.2004.03.048>

LU, D.; BATISTELLA, M.; MORAN, E. Satellite estimation of aboveground biomass and impacts of forest stand structure. *Photogrammetric Engineering & Remote Sensing*, v. 71, n. 8, p. 967-974, 2005. doi: <https://doi.org/10.14358/PERS.71.8.967>

MA, A.; LIU, B. Estimating above-ground forest biomass using Spot-5 imagery in mountainous areas. Lancaster: DEStech Publications, 2015.

MACHEKANO, H.; MUTAMISWA, R.; MVUMI, B. M. Disentangling factors limiting diamondback moth *Plutella xylostella* (L.) spatio-temporal population abundance: a tool for pest forecasting. *Journal of Applied Entomology*, v. 143, p. 670–682, 2019. DOI: 10.1111/jen.12636

MALAMBO, L. et al. Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery. *International Journal of Applied Earth Observation and Geoinformation*, v. 64, p. 31–42, 2018.

MANDAL, D. et al. Crop biophysical parameter retrieval from Sentinel-1 SAR data with a multi-target inversion of Water Cloud Model. *International Journal of Remote Sensing*, v. 41, n. 14, p. 5503–5524, 2020.

MANDAL, D. et al. Dual polarimetric Radar Vegetation Index for crop growth monitoring using Sentinel-1 SAR data. *Remote Sensing of Environment*, v. 247, 111954, 2020.

MANDAL, D. et al. Sen4Rice: A Processing Chain for Differentiating Early and Late Transplanted Rice Using Time-Series Sentinel-1 SAR Data With Google Earth Engine. *IEEE Geoscience and Remote Sensing Letters*, v. 15, n. 12, p. 1947–1951, 2018.

MARICONI, F. A. M. Inseticidas e seu emprego no combate às pragas. In: *Defensivos*. São Paulo: Agronômica Ceres, 1981. v. 1, p. 607.

MATRANGOLO, C. A. R. et al. Crescimento de eucalipto sob efeito de desfolhamento artificial. *Pesquisa Agropecuária Brasileira*, v. 45, p. 952–957, 2010.

MEIGS, G. W.; KENNEDY, R. E.; COHEN, W. B. A Landsat time series approach to characterize bark beetle and defoliator impacts on tree mortality and surface fuels in conifer forests. *Remote Sensing of Environment*, v. 115, n. 12, p. 3707–3718, 2011.

MEISSLE, M.; ROMEIS, J.; BIGLER, F. Bt maize and integrated pest management—a European perspective. *Pest Management Science*, v. 67, p. 1049–1058, 2011.

MENDES FILHO, J. M. A. Técnicas de combate à formiga. *Circular Técnica*, Instituto de Pesquisas e Estudos Florestais, n. 75, p. 1–19, 1979.

MIDI, H.; SARKAR, S. K.; RANA, S. Collinearity diagnostics of binary logistic regression model. *Journal of Interdisciplinary Mathematics*, v. 13, n. 3, p. 253–267, 2010.

- MINH, D. H. T. et al. Deep recurrent neural networks for mapping winter vegetation quality coverage via multi-temporal Sentinel-1 SAR. arXiv [cs.CV], 2017.
- MITCHARD, E. T. A. et al. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lopé National Park, Gabon: overcoming problems of high biomass and persistent cloud. *Biogeosciences*, v. 9, n. 1, p. 179–191, 2012.
- MONSALVE-TELLEZ, J. M.; TORRES-LEÓN, J. L.; GARCÉS-GÓMEZ, Y. A. Avaliação de métodos de fusão de imagens SAR e ópticas na classificação da cobertura vegetal da palma de óleo usando o algoritmo Random Forest. *Agriculture*, v. 12, n. 7, 955, 2022.
- MOSHOU, D. et al. Plant disease detection based on data fusion of hyperspectral and multi-spectral fluorescence imaging using Kohonen maps. *Real-Time Imaging*, v. 11, n. 2, p. 75–83, 2005.
- MOVCHAN, D.; BILOUS, A.; YELISTRATOVA, L.; APOSTOLOV, A.; HODOROVSKY, A. Application of various approaches of multispectral and radar data fusion for modelling of aboveground forest biomass. *Folia Forestalia Polonica. Series A. Forestry*, v. 65, n. 2, 2023.
- 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*, v. 8, p. 231–239, 2017.
- NACCARATA, V. Evaluacion de daños por bachacos (*Atta spp.*) en plantaciones jóvenes de pino caribe. Caracas: Campaña Nacional de Reforestacion, 1983. 16 p. Acesso em: 20 jun. 2023.
- NATRAS, R.; SCHMIDT, M. Machine learning model development for space weather forecasting in the ionosphere. In: *CEUR Workshop Proceedings, Gold Coast*, 1–5 Nov. 2021. v. 3052.
- NAVALGUND, R. R.; JAYARAMAN, V.; ROY, P. S. Remote sensing applications: An overview. *Current Science*, v. 93, p. 1747–1766, 2007.
- NGUYEN, D. B.; GRUBER, A.; WAGNER, W. Mapping rice extent and cropping scheme in the Mekong Delta using Sentinel-1A data. *Remote Sensing Letters*, v. 7, n. 12, p. 1209–1218, 2016.
- OLIVEIRA, M. A. et al. The Simulated Effect of Defoliation in the Growth of the *Eucalyptus grandis*. *Chemical Engineering Transactions*, v. 39, p. 1543–1548, 2014.
- ORDISH, G. F.A.O. Symposium on Integrated Pest Control. *International Journal of Pest Management: Part A*, v. 12, n. 1-2, p. 35–39, 1966.
- O'BRIEN, R. M. A caution regarding rules of thumb for variance inflation factors. *Quality & Quantity*, v. 41, n. 5, p. 673–690, 2007.
- PASQUARELLA, V. J.; HOLDEN, C. E.; WOODCOCK, C. E. Improved mapping of forest type using spectral-temporal Landsat features. *Remote Sensing of Environment*, v. 210, p. 193–207, 2018.

- PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. *Remote Sensing of Environment*, v. 217, p. 537–549, 2018.
- PEÑA, J. et al. Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. *Sensors*, v. 15, p. 5609–5626, 2015.
- PONOMAREV, V. I.; NAPALKOVA, V. V.; KLOBUKOV, G. I. Forecasting the phenology of gypsy moth development... *AIP Conference Proceedings*, v. 2063, 040042, 2019. DOI: 10.1063/1.5087374
- QUANG, N. et al. Multi-decadal changes in mangrove extent, age and species in the Red River Estuaries of Vietnam. *Remote Sensing*, v. 12, 2289, 2020.
- R CORE TEAM. R: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2023.
- RACZKO, E.; ZAGAJEWSKI, B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. *European Journal of Remote Sensing*, v. 50, p. 144–154, 2017.
- RAGSDALE, D. W. et al. Ecologia e manejo do pulgão da soja na América do Norte. *Annual Review of Entomology*, v. 56, p. 375–399, 2011.
- RASMUSSEN, J. et al. Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, v. 74, p. 75–92, 2016.
- REIGBER, A. et al. The High-Resolution Digital-Beamforming Airborne SAR System DBFSAR. *Remote Sensing*, v. 12, n. 11, 2020.
- REIS FILHO, W. et al. Danos causados por diferentes níveis de desfolha artificial para simulação do ataque de formigas cortadeiras em *Pinus taeda* e *Eucalyptus grandis*. *Pesquisa Florestal Brasileira*, v. 31, n. 65, p. 37, 2011.
- REIS, M. A. et al. Amostragem de formigas-cortadeiras (Hymenoptera: Formicidae) em eucaliptais pelos métodos de transectos em faixa e em linha. *Revista Árvore*, v. 34, n. 6, p. 1101–1108, 2010.
- REZENDE, J. P.; PEREIRA, A. R.; OLIVEIRA, A. D. Espaçamento ótimo para a produção de madeira. *Revista Árvore*, v. 7, p. 30–43, 1983.
- ROCHA, S. L. et al. Quality control by leaf-cutting ants: evidence from communities of endophytic fungi in foraged and rejected vegetation. *Arthropod-Plant Interactions*, v. 8, n. 5, p. 485–493, 2014.
- RODRÍGUEZ, J. et al. Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, v. 184, 106061, 2021.

- ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: Third ERTS Symposium. NASA, Washington, D.C., 1974. p. 309–317.
- ROY, P. S.; BEHERA, M. D.; SRIVASTAV, S. K. Satellite remote sensing: Sensors, applications and techniques. Proceedings of the National Academy of Sciences, India. Section A: Physical Sciences, v. 87, p. 465–472, 2017.
- SAATCHI, S. SAR methods for mapping and monitoring forest biomass. In: FLORES-ANDERSON, A. I.; HERNDON, K. E.; THAPA, R. B.; CHERRINGTON, E. (eds.). The Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation. Huntsville: NASA, 2019.
- SANGÜESA-BARREDA, G. et al. Remote-sensing and tree-ring based characterization of forest defoliation and growth loss due to the Mediterranean pine processionary moth. *Forest Ecology and Management*, v. 320, p. 171–181, 2014.
- SANO, E. E. et al. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. *International Journal of Remote Sensing*, v. 28, n. 12, p. 2739–2752, 2007.
- SANTOS, A. D. et al. Canopy defoliation by leaf-cutting ants in eucalyptus plantations inferred by unsupervised machine learning applied to remote sensing. *Precision Agriculture*, v. 23, n. 6, p. 2253–2269, 2022.
- SANTOS, A. et al. Multispectral characterization, prediction and mapping of *Thaumastocoris peregrinus* attack in Eucalyptus plantations using remote sensing. *Journal of Spatial Science*, v. 62, n. 1, p. 127–137, 2016.
- SANTOS, E. P. et al. Sentinel-1 imagery used for estimation of soil organic carbon by dual-polarization SAR vegetation indices. *Remote Sensing*, v. 15, 5464, 2023.
- SENTHILNATH, J. et al. Application of UAV imaging platform for vegetation analysis based on spectral-spatial method. *Computers and Electronics in Agriculture*, v. 140, p. 8–24, 2017.
- SEPULCRE-CANTÓ, G. et al. Detection of water stress in an olive orchard with thermal remote sensing imagery. *Agricultural and Forest Meteorology*, v. 136, p. 31–44, 2006.
- SINHA, S. et al. Modelo de dados SAR bi-sensor integrado baseado em regressão para estimar o estoque de carbono florestal. *Journal of the Indian Society of Remote Sensing*, v. 47, n. 9, p. 1599–1608, 2019. doi: <https://doi.org/10.1007/s12524-019-01004-7>
- SHAO, G. et al. Mapping hardwood forests through a two-stage unsupervised classification by integrating Landsat Thematic Mapper and forest inventory data. *Journal of Applied Remote Sensing*, v. 8, 083546, 2014.
- SHIVAPRAKASH, K. N. et al. Potential for artificial intelligence (AI) and machine learning (ML) applications in biodiversity conservation, managing forests, and related services in India. *Sustainability*, v. 14, n. 12, 7154, 2022.

- SINGHAL, J.; KUMAR, T.; FARARODA, R.; DAS, P. K.; PALIWAL, R.; CHINTALA, S. R.; RAJASHEKAR, G. Forest characterization using C-band SAR data—Initial results of EOS-04 data. *Journal of the Indian Society of Remote Sensing*, v. 52, n. 4, p. 787–800, 2024.
- SPRUCE, J. P. et al. Assessment of MODIS NDVI time series data products for detecting forest defoliation by gypsy moth outbreaks. *Remote Sensing of Environment*, v. 115, n. 2, p. 427–437, 2011.
- STANKEVICH, S.A.; KOZLOVA, A.A.; PIESTOVA, I.O.; LUBSKYI, M.S. Leaf area index estimation of forest using sentinel-1 C-band SAR data. In: 2017 IEEE Microwaves, Radar and Remote Sensing Symposium (MRRS). IEEE, 2017. p. 253-256. doi: <https://doi.org/10.1109/MRRS.2017.8075075>.
- STAPE, J. L. et al. The Brazil Eucalyptus Potential Productivity Project: Influence of water, nutrients and stand uniformity on wood production. *Forest Ecology and Management*, v. 259, n. 9, p. 1684-1694, 2010. doi: <https://doi.org/10.1016/j.foreco.2010.01.012>
- SUGIURA, R. et al. Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*, v. 148, p. 1–10, 2016.
- SZIGARSKI, C. et al. Analysis of the Radar Vegetation Index and Potential Improvements. *Remote Sensing*, v. 10, n. 11, 2018.
- TRANSON, J. et al. Survey of Hyperspectral Earth Observation Applications from Space in the Sentinel-2 Context. *Remote Sensing*, v. 10, n. 2, p. 157–189, 2018.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979.
- VAN TRICHT, K. et al. Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium. *Remote Sensing*, v. 10, n. 10, 2018.
- VAN ZYL, J. J.; KIM, Y. J. *Synthetic Aperture Radar Polarimetry*. New York: Wiley, 2011.
- VAPNIK, V. N. *The Nature of Statistical Learning Theory*. New York: Springer, 1995. 314 p. ISBN 978-1-4757-3264-1.
- VILELA, E. Status of Leaf-Cutting Ant Control in Forest Plantations in Brazil. p. 399–408, 1986.
- VIRNODKAR, S. S. et al. Remote sensing and machine learning for crop water stress determination in various crops: A critical review. *Precision Agriculture*, v. 21, p. 1121–1155, 2020.
- VUOLO, F. et al. How much does multi-temporal Sentinel-2 data improve crop type classification? *International Journal of Applied Earth Observation and Geoinformation*, v. 72, p. 122–130, 2018.

WANG, J. et al. Review of satellite remote sensing use in forest health studies. *The Open Geography Journal*, v. 3, p. 28–42, 2010.

WANG, K. et al. Remote sensing of ecology, biodiversity, and conservation: A review from the perspective of remote sensing specialists. *Sensors*, v. 10, p. 9647–9667, 2010.

WANG, L.; HUANG, H.; LUO, Y. Remote sensing of insect pests in larch forest based on physical model. In: *IEEE International Geoscience and Remote Sensing Symposium – IGARSS 2010*. 2010.

WANG, Y. et al. Analysis of the application of machine learning algorithms based on Sentinel-1/2 and Landsat-8 OLI data in estimating above-ground biomass of subtropical forests. *Forests*, v. 16, n. 4, 559, 2025.

WANG, Z. et al. Aboveground woody biomass estimation in an agroforestry area using airborne LiDAR and hyperspectral data: Individual tree analysis incorporating species information. *Journal of Applied Remote Sensing*, v. 10, 036007, 2016.

WASER, L. T. et al. Mapping dominant leaf type based on combined Sentinel-1/-2 data: Challenges for mountainous countries. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 180, p. 209–226, 2021.

WASSOUF, W. N.; ALKHATIB, R.; SALLOUM, K.; BALLOUL, S. Predictive analytics using big data for increased customer loyalty: Syriatel Telecom Company case study. *Journal of Big Data*, v. 7, 29, 2020.

WEISS, M.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, v. 236, 111402, 2020.

WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. *Remote Sensing*, v. 10, 1419, 2018.

WHITCRAFT, A. K. et al. Cloud cover throughout the agricultural growing season: impacts on passive optical earth observations. *Remote Sensing of Environment*, v. 156, p. 438–447, 2015.

WISEMAN, G. et al. RADARSAT-2 Polarimetric SAR Response to Crop Biomass for Agricultural Production Monitoring. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 11, p. 4461–4471, 2014.

WOODHOUSE, I. H. *Introduction to Microwave Remote Sensing*. Boca Raton: CRC Press, 2006. ISBN 0-415-27123-1.

XIA, D. et al. Insect Detection and Classification Based on an Improved Convolutional Neural Network. *Sensors*, v. 18, n. 12, 2018.

ZAGAJEWSKI, B. et al. Comparison of random forest, support vector machines and neural networks for post-disaster forest species mapping of the Krkonoše/Karkonosze transboundary biosphere reserve. *Remote Sensing*, v. 13, n. 13, 2581, 2021.

- ZANETTI, R. et al. An overview of integrated management of leaf-cutting ants (Hymenoptera: Formicidae) in Brazilian forest plantations. *Forests*, v. 5, p. 439–454, 2014.
- ZANETTI, R. et al. Influência da espécie cultivada e da vegetação nativa circundante na densidade de saúveiros em eucaliptais. *Pesquisa Agropecuária Brasileira*, v. 35, n. 10, p. 1911–1918, 2000.
- ZANETTI, R. et al. Level of economic damage for leaf-cutting ants (Hymenoptera: Formicidae) in Eucalyptus plantations in Brazil. *Sociobiology*, v. 42, n. 2, p. 433–442, 2003. Acesso em: 20 jun. 2023.
- ZANUNCIO, J. C. et al. Aferição de dosagens de iscas granuladas para controle de *Atta laevigata* (F. Smith) pelo número de olheiros ativos. *Revista Árvore*, v. 20, p. 241–246, 1996.
- ZANUNCIO, J. C. et al. Spatial distribution of nests of the leaf cutting ant *Atta sexdens rubropilosa* (Hymenoptera: Formicidae) in plantations of *Eucalyptus urophylla* in Brazil. *Sociobiology*, v. 39, n. 2, p. 231–242, 2002. Disponível em: . Acesso em: 20 jun. 2023.
- ZANUNCIO, J. C. et al. The impact of the Forest Stewardship Council (FSC) pesticide policy on the management of leaf-cutting ants and termites in certified forests in Brazil. *Annals of Forest Science*, v. 73, n. 2, p. 205–214, 2016.
- ZANUNCIO, J. C.; LARANJEIRO, A. J.; SOUZA, O. Controle de *Acromyrmex subterraneus Santschi* (Hymenoptera: Formicidae) com sulfluramida. *Anais da Sociedade Entomológica do Brasil*, v. 25, p. 383–388, 1996.
- ZHANG, Y.; LIU, J.; SHEN, W. A review of ensemble learning algorithms used in remote sensing applications. *Applied Sciences*, v. 12, 8654, 2022.
- ZHENG, H. et al. Performance Evaluation of Downscaling Sentinel-2 Imagery for Land Use and Land Cover Classification by Spectral-Spatial Features. *Remote Sensing*, v. 9, n. 12, 2017.
- ZHU, X.; LIU, D. Accurate mapping of forest types using dense seasonal Landsat time-series. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 96, p. 1–11, 2014.