UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO” FACULDADE DE CIÊNCIAS AGRÁRIAS DO VALE DO RIBEIRA CAMPUS REGISTRO

“ESTIMATIVA DA DENSIDADE DE PLANTAS DANINHAS EM BANANAIS UTILIZANDO IMAGENS DE DRONES”

TRABALHO ORIGINAL DE PESQUISA

JOÃO VICTOR DE ANDRADE VILELA

Trabalho de Graduação apresentado à
Faculdade de Ciências Agrárias do Vale do Ribeira
Câmpus de Registro - UNESP, para a graduação em
ENGENHARIA AGRONÔMICA

REGISTRO

1° Semestre/2025

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO” FACULDADE DE CIÊNCIAS AGRÁRIAS DO VALE DO RIBEIRA CAMPUS REGISTRO

“ESTIMATIVA DA DENSIDADE DE PLANTAS DANINHAS EM BANANAIS UTILIZANDO IMAGENS DE DRONES”

TRABALHO ORIGINAL DE PESQUISA

Orientador: Prof. Dr. Hugo do Nascimento Bendini

Coorientador: Profa. Dra. Silvia Helena Modenese Gorla da Silva

Trabalho de Graduação apresentado à
Faculdade de Ciências Agrárias do Vale do Ribeira
Câmpus de Registro - UNESP, para a graduação em
ENGENHARIA AGRONÔMICA

REGISTRO

1° Semestre/2025

V699e

Vilela, João Victor de Andrade

Estimativa da densidade de plantas daninhas em bananais utilizando imagens de drones / João Victor de Andrade Vilela. -- Registro, 2025

46 p. : il., tabs., fotos, mapas

Trabalho de conclusão de curso (Bacharelado - Engenharia Agronômica) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias do Vale do Ribeira, Registro

Orientador: Hugo do Nascimento Bendini

Coorientadora: Silvia Helena Modenese Gorla da Silva

1. Frutífera. 2. Sensoriamento Remoto. 3. Agricultura de Precisão. 4. Mapeamento de Infestação. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Registro

CERTIFICADO

TRABALHO DE GRADUAÇÃO DO CURSO DE ENGENHARIA AGRONÔMICA

TÍTULO: **"ESTIMATIVA DA DENSIDADE DE PLANTAS DANINHAS EM BANANAIS UTILIZANDO IMAGENS DE DRONES"**

ACADÊMICO: **João Victor de Andrade Vilela**

ORIENTADOR: **Prof. Dr. Hugo do Nascimento Bendini**

PERÍODO: **9º Semestre** **5º Ano**

Aprovado: [X]

Reprovado: [ ]

BANCA EXAMINADORA:

Presidente **Prof. Dr. Hugo do Nascimento Bendini**

Membro **Prof. Dr. Eduardo Nardini Gomes**

Membro **Profa. Dra. Silvia Helena Modenese Gorla da Silva**

Registro, 11 / 07 / 2025

DEDICATÓRIA

Dedico este trabalho a Deus, minha mãe, meu pai, minhas avós, meus avôs, minha irmã, minha namorada, aos meus primos e primas, tias e tios, padrinho e madrinha, amigos, colegas, professores e funcionários da universidade.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus, por todas as bençãos em minha vida, saúde, aprendizado e força para enfrentar os desafios da vida.

Agradeço a minha mãe Daniela, por todo apoio em minha vida, cuidados, ensinamentos, boas risadas e sempre confiar em mim.

Agradeço ao meu pai, Carlos Henrique, por me ensinar, cuidar, apoiar e me proporcionar o estudo em uma faculdade de excelência.

Agradeço as minhas avós, Ana Célia e Joana D'Arc, por sempre cuidarem de mim, pelos ensinamentos, carinho e as melhores comidas do mundo.

Agradeço aos meus avôs, Odair "in memoriam" e José Milton.

Agradeço a minha tia Viviane, minha irmã Alice, meu primo Romeo e minha prima Mariana.

Gostaria de agradecer a minha namorada, Josielly Cristina, por sempre confiar em mim, por todo o carinho, amor e cuidado.

Gostaria de agradecer aos meus amigos de faculdade, Marcos Alexandre, Tiago Oliveira, Hebert Lucas, Pedro Andreas, Guilherme Viveiros, Daniel Yuen, Eduardo Cerrades e a todas as amizades que nasceram na faculdade.

Agradeço ao Prof. Dr. Hugo Bendini por ter aceitado ser meu orientador e por todo ensinamento durante o desenvolvimento do trabalho.

Agradeço a Prof. Dr. Silvia Helena, por aceitar ser minha coorientadora e participar do desenvolvimento do projeto.

Agradeço ao Prof. Dr. Leandro Godoy, por ceder o bananal para realização do projeto.

Agradeço a todos os professores que contribuíram para minha formação, com aulas e conversas produtivas.

Agradeço a todos os funcionários do Campus de Registro – SP.

Agradeço a UNESP - Faculdade de Ciências Agrárias do Vale do Ribeira FCAVR, por oferecer ensino de excelente qualidade e pelo acolhimento.

Muito obrigado a todos!

EPÍGRAFE

"Ainda que eu andasse pelo vale da sombra da morte, não temeria mal algum, porque tu estás comigo; a tua vara e o teu cajado me consolam."

Salmos 23:4.

RESUMO

A bananicultura ocupa um papel de destaque na produção agrícola mundial, sendo a banana a fruta mais consumida in natura. O Brasil ocupa o quinto lugar de maior produtor global, com o Estado de São Paulo liderando a produção nacional. O Vale do Ribeira apresenta destaque estadual, pois é responsável por mais de 70% da produção paulista, evidenciando a relevância econômica e social da cultura para a região. Entre os principais fatores que comprometem a produtividade da bananeira está a presença de plantas daninhas, que competem por nutrientes, dificultam práticas culturais e podem servir de abrigo para pragas e patógenos. Com o avanço da agricultura de precisão, o uso de tecnologias como drones e sensores embarcados tem ganhado espaço. Ainda existe uma lacuna na literatura científica, principalmente na cultura da banana, para a identificação e quantificação de daninhas. Nesse contexto, o presente trabalho teve como objetivo estimar a densidade de plantas daninhas em bananais, a partir de imagens RGB (*Red, Green, Blue*) obtidas por drones. O estudo foi realizado no município de Registro/SP, na unidade da UNESP – Fazenda Agrochá. Foram realizadas capturas aéreas com drone DJI Mavic Air 3, além de coleta de pontos com GPS Garmin, posteriormente georreferenciados com auxílio do software Quantum GIS (QGIS). Para reduzir a subjetividade na análise, foi desenvolvida uma escala com fotos, permitindo a atribuição de notas com maior precisão para avalições de foco das plantas daninhas, realizadas a campo por avaliadores. As imagens foram submetidas a técnicas de processamento digital de imagens (PDI), envolvendo classificação não supervisionada, reclassificação para binarização das imagens, visando separar visualmente áreas ocupadas pela cultura de interesse e as plantas daninhas. Em seguida, foram extraídos atributos estatísticos zonais das imagens originais e com as folhas removidas (mascaradas), e eles foram analisados por meio de uma análise de correlação, e modelagem preditiva utilizando o algoritmo Random Forest, por meio do software Weka. Os resultados indicaram que as imagens mascaradas apresentaram maior correlação com os dados de campo, com um valor de 0,52, resultado obtido com um conjunto teste de 66% e 33% dos dados remanescente para validação, já o R^2 da predição das notas do campo, considerando o conjunto total com 66% dos dados utilizados para treinamento e posteriormente a validação com o conjunto completo dos dados, foi de 0,60, demonstrando uma relação moderada entre esses valores. Apesar dos resultados serem limitados à área de estudo, e não permitirem concluir sobre a viabilidade da metodologia proposta para aplicação operacional, foi demonstrado o potencial da integração entre drones, PDI e algoritmos de aprendizado de máquina para

o monitoramento de plantas daninhas em bananais. Além disso, os resultados encorajam o desenvolvimento de futuras pesquisas com outras técnicas de PDI, como o uso de métricas de textura, diferentes algoritmos de regressão, além de outros sensores, como multiespectrais e termais.

Palavras-chave: Frutífera, sensoriamento remoto, agricultura de precisão, mapeamento de infestação

ABSTRACT

Banana cultivation plays a prominent role in global agricultural production, with bananas being the most consumed fresh fruit worldwide. Brazil ranks fifth among the largest global producers, with the state of São Paulo leading national production. The Vale do Ribeira region stands out within the state, accounting for over 70% of São Paulo's output, underscoring the crop's socioeconomic relevance in the region. One of the main factors affecting banana productivity is weed infestation, which competes for nutrients, hinders cultural practices, and may harbor pests and pathogens. With the advancement of precision agriculture, the use of technologies such as drones and onboard sensors has gained space. However, a gap persists in the scientific literature, especially regarding the identification and quantification of weeds in banana crops. In this context, the present study aimed to estimate weed density in banana plantations using RGB (Red, Green, Blue) images captured by drones. The research was conducted in Registro/SP, at the UNESP experimental farm Agrochá. Aerial imagery was obtained with a DJI Mavic Air 3 drone, and control points were collected using a Garmin GPS, later georeferenced through the Quantum GIS (QGIS) software. To reduce subjectivity in visual analysis, a photographic scale was developed to allow evaluators to assign more precise scores to weed infestation in the field. The images underwent digital image processing (DIP) techniques, including unsupervised classification and binarization, aiming to visually separate crop areas from weed-infested regions. Subsequently, zonal statistical attributes were extracted from the original and masked images (with banana leaves removed), and analyzed through correlation analysis and predictive modeling using the Random Forest algorithm within Weka software. Results showed that the masked images had a higher correlation with field data ($r = 0.52$), obtained from a training set comprising 66% of the data and a validation set with the remaining 33%. The R^2 for field score prediction using the full dataset, trained on 66% and later validated on the complete set, reached 0.60, indicating a moderate relationship. Although the findings are limited to the study area and do not confirm operational viability, the potential of integrating drones, DIP techniques, and machine learning algorithms for weed monitoring in banana plantations is evident. The results also encourage future research using other DIP techniques—such as texture metrics, alternative regression algorithms, and different sensors, including multispectral and thermal imaging.

Keywords: fruit crop, remote sensing, precision agriculture, infestation mapping.

SUMÁRIO

1. INTRODUÇÃO 12
2. REVISÃO BIBLIOGRÁFICA 15
2.1. Cultura da Bananeira 15
2.2. Sensoriamento Remoto e Processamento Digital de Imagens 16
2.3. Inteligência Artificial na Agricultura 19
3. MATERIAL E MÉTODOS 21
3.1 Localização da Área 21
3.2 Materiais 21
3.3 Desenvolvimento Metodológico 22
3.3.1 Aquisição das Imagens 22
3.3.2. Georreferenciamento das Imagens 23
3.3.3 Escala de Fotos e Amostragem 25
3.3.4. Classificação Não Supervisionada 27
3.3.5 Binarização 27
3.3.6 Mascaramento 27
3.3.7 Extração dos Atributos com Operador Zonal 28
3.4 Modelagem e Análise dos Resultados 28
4. RESULTADOS E DISCUSSÕES 30
5. CONCLUSÃO 40
6. REFERÊNCIAS BIBLIOGRÁFICAS 41
APÊNDICE A. Tabelas com os valores dos atributos extraídos pelo operador zonal (imagem original e mascarada) 46

1. INTRODUÇÃO

A cultura da bananeira (*Musa* spp.) é de extrema importância para a agricultura mundial, pois além de gerar milhares de empregos, é a fruta mais consumida no mundo por todas as classes sociais, além disso, o Brasil, quinto maior produtor mundial, com uma área de produção com pouco mais de 456.000 hectares, consegue atingir números superiores a 6,8 milhões de toneladas produzidas (FAO, 2023). O Estado de São Paulo é o maior produtor nacional, possuindo uma área de plantio com pouco mais de 45.600 hectares, e produção de mais do que 958.000 toneladas, o que equivale a 13,7% de toda a produção nacional. A região com maior destaque no estado é o Vale do Ribeira, responsável por mais do que 70% de toda a produção estadual (IBGE, 2024). Devido a sua elevada expressão socioeconômica, torna-se necessário o desenvolvimento de tecnologias que auxiliem os produtores a alcançarem a máxima produção de suas áreas. Um dos grandes problemas na produção de banana são as plantas daninhas, pois além de competirem por água, luz, nutrientes e espaço, elas também podem ser vetores de doenças e pragas (GOMES et al., 2010).

A adoção de ações de controle durante o período de maior vulnerabilidade, até cinco meses após o plantio das mudas, é fundamental para maximizar a capacidade competitiva da cultura contra a comunidade daninha (EMBRAPA, 2010). O controle cultural de plantas daninhas evidencia uma forma de manejo eficiente e com menores custos de implantação. O espaçamento entre linhas e a densidade de plantio podem influenciar a capacidade da cultura em competir com as plantas daninhas por recursos e, portanto, pode afetar o manejo dessas espécies (ISAAC et al., 2007).

O controle de plantas daninhas por meio de herbicidas específicos é a principal técnica de controle utilizado ao redor do mundo (CHENG et al., 2021). O controle químico tradicional dar-se por meio da remoção das plantas pela aplicação uniforme em toda a área cultivada, o que resulta em pulverização excessiva em áreas livres de plantas daninhas, sendo que tal abordagem resulta em grande geração de resíduos e poluição do ambiente agrícola (CHIVASA et al., 2021).

Desta forma, o uso de tecnologias digitais visando o mapeamento da infestação e identificação das espécies de plantas daninhas, combinado aos estudos fitossociológicos que inclui a previsão da composição e a densidade de sementes presentes no banco de sementes, podem auxiliar o produtor na melhor decisão de manejo, uma vez que as informações passam a ser mais assertivas e eficientes (PEÑA et al., 2015; OLIVEIRA et al., 2020).

Com o avanço das tecnologias, os sensores remotos para imageamento, embarcados em aeronaves ou em implementos agrícolas para identificação das plantas daninhas vem melhorando a precisão do mapeamento destes alvos (GAGO et al., 2015). Tal fato pode ser relacionado à integração desses sensores ao uso de técnicas computacionais mais avançadas, como a inteligência artificial, o que auxilia na tomada de decisões (HUANG et al., 2018).

Os veículos aéreos não tripulados (VANT) ou drones têm revelado um grande potencial de aplicações de estudos de trabalhos com plantas daninhas, uma vez que possuem facilidade de uso e elevado custo-benefício para aquisição de dados (RODRIGUEZ et al., 2021). Com a utilização de VANT, Arantes et. al., (2019) obtiveram sucesso no mapeamento de plantas daninhas presentes em plantações de mandioca, utilizando-se de índices de vegetação. Tais equipamentos são considerados plataformas úteis para embarcar tecnologias e sensores para aplicação na agricultura (MALAMIRI et al., 2021), além disso, a utilização de drones equipados com câmeras RGB (*Red, Green, Blue*) tem demonstrado potencial real na identificação de plantas daninhas em campo. Estudos como o de Yano et al. (2022) evidenciam resultados práticos, com níveis de acurácia entre 72% e 77% na cultura da cana de açúcar, o que reforça a aplicabilidade da abordagem no manejo de infestantes em lavouras extensivas e justificam a escolha da metodologia no presente trabalho. Os sensores para estudo das plantas daninhas podem estar embarcados nos drones e terem diferentes níveis tecnológicos, que vão de sensores mais econômicos com aquisição de imagem RGB, passando por sensores multiespectrais com maior resolução espectral (incluindo bandas nas regiões do infravermelho, por exemplo), ou até mesmo hiperespectrais (com dezenas ou centenas de bandas espectrais). Dispondo de altíssima resolução espacial (pixels com tamanhos na ordem de centímetros), e com diferentes resoluções espectrais, essas imagens apresentam um grande potencial para serem utilizadas no monitoramento de plantas invasoras, viabilizando o manejo correto das mesmas (CAO et al., 2020).

O uso de técnicas de processamento digital de imagens (PDI) aplicado a culturas agronômicas destaca-se pelo grande potencial para subsidiar na tomada de decisão no ambiente agrícola, reduzindo o tempo e custo de observação no campo (JORGE; CRESTANA, 2007). O processamento digital de imagens é caracterizado por envolver um conjunto de técnicas aplicadas sobre imagens digitais com o objetivo de realçar, segmentar e extrair informações específicas de interesse (GONZALEZ; WOODS, 2011). De acordo com o INPE (2006), análise de dados multidimensionais, adquiridas através de sensores ou drones, são conhecidas como PDI, pois para interpretar seus resultados, os arquivos de entrada e saída são imagens, e a partir

do que é gerado durante essas fases de interpretação, é possível gerar mais produtos para processamentos posteriores.

As técnicas de aprendizado de máquina, são um campo de estudo dentro da área de Inteligência Artificial, e têm o objetivo de aprender com padrões, a partir de um processo de treinamento supervisionado ou não supervisionado, buscando minimizar o erro entre a verdade de campo e valor predito pelo modelo. Essas técnicas são muito utilizadas em problemas de classificação e regressão, no processamento digital de imagens, e envolvem algoritmos como florestas aleatórias (ou no inglês, *Random Forest*) (BREIMAN, 2001), RNA (Redes Neurais Artificiais) e máquinas de vetores de suporte (*Support Vector Machine – SVM*) (CORTES; VAPNIK, 1995). Pesquisas como as de Lottes et al. (2017) e Peña et al. (2015), demonstram a eficácia da combinação entre imagens obtidas por drones e algoritmos de aprendizado de máquina na identificação de plantas daninhas em diversas culturas agrícolas.

Ainda existe uma lacuna na literatura científica, no que tange a gama de possíveis técnicas de inteligência artificial no processamento das imagens aplicadas no manejo agronômico, principalmente considerando estudos relacionados a identificação e quantificação de plantas daninhas na cultura da bananeira.

Dessa maneira o objetivo do trabalho foi desenvolver uma metodologia capaz de estimar a densidade de plantas daninhas em bananais, por meio do uso de imagens de drone e técnicas de processamento digital de imagens e aprendizado de máquina.

2. REVISÃO BIBLIOGRÁFICA

2.1. Cultura da Bananeira

A cultura da bananeira (*Musa spp.*) é uma das mais importantes para a agricultura mundial, destacando-se tanto pelo volume de produção quanto por sua presença significativa na dieta alimentar global. Segundo a FAO (2023), o Brasil ocupa a quinta posição entre os maiores produtores mundiais de banana, com uma área cultivada superior a 450 mil hectares e uma produção anual de aproximadamente 6,7 milhões de toneladas. O Estado de São Paulo contribui com cerca de 12% dessa produção, sendo o Vale do Ribeira a principal região produtora estadual, concentrando mais de 80% da produção paulista (IBGE, 2024). De acordo com Frizo (2015), mais de 90% das propriedades produtoras de banana no Vale do Ribeira são classificadas como pertencentes à agricultura familiar, evidenciando a importância socioeconômica da cultura para pequenos produtores rurais.

Agronomicamente, a bananeira é uma planta perene, com sistema radicular superficial e alta exigência hídrica e nutricional (SOUZA et al., 2010). Essas características a tornam vulnerável a fatores ambientais adversos, incluindo a competição com plantas daninhas, que podem comprometer o desenvolvimento inicial da cultura (EMBRAPA, 2010).

As plantas daninhas representam um dos principais desafios fitossanitários para a bananicultura, especialmente em regiões tropicais como o Vale do Ribeira. Essas espécies competem diretamente por recursos como água, luz, nutrientes e espaço, podendo reduzir o crescimento vegetativo e a produtividade da bananeira (ALMEIDA et al., 2018). Segundo Gomes et al. (2010), “a competição com plantas daninhas durante os estágios iniciais de desenvolvimento da bananeira é particularmente prejudicial, podendo comprometer a formação adequada do sistema radicular e a emissão das primeiras folhas”. A fase mais crítica de interferência é reconhecida nos cinco primeiros meses após o plantio, exigindo atenção especial no manejo (EMBRAPA, 2010).

Além da competição direta, as plantas daninhas também atuam como hospedeiras de pragas e doenças. Oliveira e Souza (2000) destacam que a vegetação espontânea serve como abrigo para pragas agrícolas como a broca-do-rizoma (*Cosmopolites sordidus*), além de favorecer a ocorrência de patógenos de solo. Estudos fitossociológicos realizados por Oliveira et al. (2017) identificaram uma elevada diversidade de plantas daninhas em bananais do Vale do Ribeira, com predominância de espécies das famílias Poaceae, Cyperaceae e Asteraceae. Os

autores ressaltam a importância de estratégias de manejo específicas e integradas para o controle dessas espécies.

Os métodos de controle mais utilizados são a capina manual, a roçada e a aplicação de herbicidas. No entanto, o uso excessivo de defensivos químicos pode causar impactos ambientais significativos, como contaminação de recursos hídricos e redução da biodiversidade (CHIVASA et al., 2021).

2.2. Sensoriamento Remoto e Processamento Digital de Imagens

O sensoriamento remoto é uma ferramenta cada vez mais integrada à agricultura de precisão, oferecendo dados cruciais para o acompanhamento da saúde das lavouras, do solo e de fatores ambientais. De acordo com Surendran (2024), essa tecnologia permite a obtenção de informações sobre uma área ou objeto sem a necessidade de contato direto, por meio de sensores instalados em plataformas como drones, satélites ou equipamentos terrestres. Isso possibilita uma tomada de decisão mais eficiente, reduzindo custos operacionais e aumentando a produtividade de forma sustentável. Os Veículos Aéreos Não Tripulados (VANT), conhecidos popularmente como drones, vêm se destacando como ferramentas fundamentais na agricultura de precisão. Sua capacidade de captar imagens aéreas com alta resolução espacial, aliada à agilidade nas operações e ao baixo custo, tem tornado seu uso viável não apenas em grandes propriedades, mas também entre pequenos e médios produtores. De acordo com Li e Li (2025), a integração de sensores multiespectrais e algoritmos de inteligência artificial nesses equipamentos tem ampliado significativamente seu potencial, permitindo o mapeamento detalhado de áreas cultivadas, a identificação de plantas daninhas e a tomada de decisões agronômicas com maior assertividade e economia Os sensores remotos mais comuns embarcados em drones para agricultura são as câmeras RGB, multiespectrais e hiperespectrais, possibilitando aplicações como detecção de estresse hídrico, monitoramento nutricional e identificação de plantas daninhas (GAGO et al., 2015). Ao realizar um mapeamento aéreo, o VANT registra imagens sobrepostas de alta resolução espacial da região de interesse, que posteriormente são agrupadas em um único mapa ortomosaico georreferenciado de alta resolução, cobrindo áreas (talhões) agrícolas de pequeno/médio porte (SUZUKI et al. 2010). Com estes mapas georreferenciados, é possível obter informações sobre a localização, distribuição e variabilidade das plantas invasoras no campo.

Uma imagem digital pode ser definida como uma função f (x, y) em que tanto o domínio quanto a imagem são valores finitos e discretos. As variáveis x e y são coordenadas espaciais no plano cartesiano, enquanto a amplitude de f no ponto (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Cada par (x, y) é denominado de pixel e este é definido como o elemento básico de uma imagem (GONZALES; WOODS 2011). A Figura 1 demonstra o conceito básico de pixel.

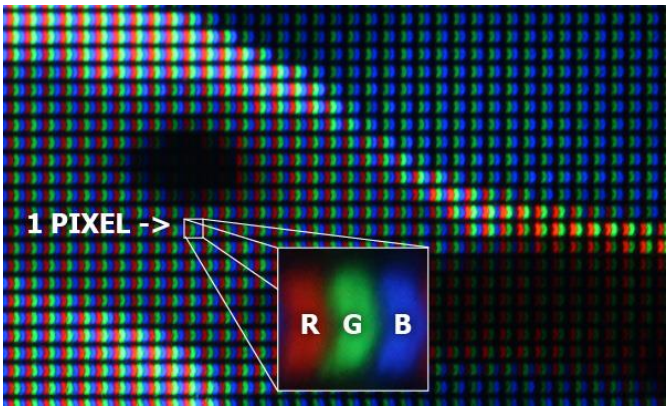

Figura 1 – Demonstração do que é um pixel. Fonte: Retirado de Lungov (2016).

O processamento digital de imagens envolve um conjunto de técnicas aplicadas sobre imagens digitais com o objetivo de realçar, segmentar e extrair informações específicas de interesse (GONZALEZ; WOODS, 2011).

Na agricultura, essas técnicas são empregadas em diversas aplicações, como por exemplo mapeamento de culturas, detecção de falhas de plantio e identificação de plantas daninhas (LOTTES et al., 2017). Segundo Zhang (2020), o desenvolvimento da tecnologia de PDI e reconhecimento de plantas daninhas no estágio de plântula de milho, integrando inteligência artificial, permite identificar com precisão as infestantes e aplicar herbicida de forma direcionada, promovendo a agricultura de precisão.

As etapas básicas do PDI o incluem: 1) pré-processamento das imagens, envolvendo por exemplo técnicas de realce, correção radiométrica, geométrica; 2) segmentação e classificação (técnicas para agrupar, em regiões na imagem, pixels com valores similares, ou que caracterizem um padrão específico); 3) extração de características espectrais, texturais e morfológicas (YANG et al., 2019); e 4) Análise dos resultados para geração de uma informação útil para tomada de decisão em um sistema.

As técnicas de classificação de imagens podem ser separadas entre técnicas supervisionadas e não-supervisionadas. No aprendizado supervisionado, os modelos aprendem

com um conjunto de dados que possuem a resposta de saída associadas. O objetivo do aprendizado supervisionado é criar um modelo que possa mapear entrada para a sua respectiva saída, desse modo podendo predizer a saída correta para novas entradas não rotuladas. No aprendizado não supervisionado, o conjunto de dados fornecido ao modelo possui apenas as entradas, sem rótulos de saída. O intuito do aprendizado não supervisionado é procurar padrões entre os dados, formando clusters ou agrupamentos como saída (ARAÚJO, 2021).

Entre os métodos não-supervisionados, para realizar um agrupamento sobre um conjunto de dados, o algoritmo K-médias é um dos mais simples e populares (MACQUEEN, 1967). Esse algoritmo agrupa os dados que mais se aproximam entre si, e para representá-los cria-se um centroide, de modo que um agrupamento (cluster) possua um centroide e os dados selecionados. O algoritmo tem como parâmetros a quantidade de agrupamentos, nomeada de K, a métrica que mede a similaridade dos dados e a inicialização aleatória. A métrica mais utilizada é a distância Euclidiana ao quadrado, devido a existência e unicidade do ponto que a minimiza e este mesmo ponto, sendo o centroide, descrito matematicamente pela média aritmética. A Figura 2 abaixo demonstra como o K-médias funciona.

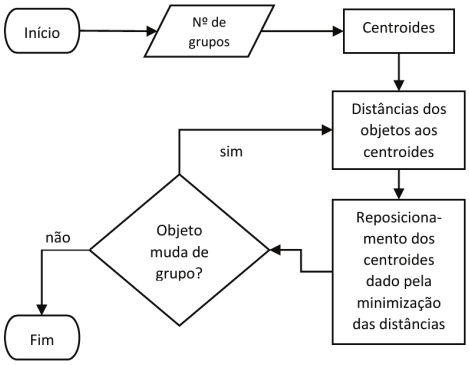

Figura 2 – Fluxograma do funcionamento do K-médias. Fonte: Retirado de Marília Magalhães Maia (2021).

A binarização de imagens, também conhecida como limiarização, é uma técnica de PDI aplicado à agricultura, muito utilizada na identificação de plantas daninhas. Conforme destacado por Hassanein et al. (2018), tais imagens binárias de vegetação podem ser usadas para o manejo de plantas daninhas, detecção de linhas de cultivo e monitoramento da saúde das culturas. Essa técnica permite separar objetos de interesse, como as folhas de uma vegetação, do solo na imagem, facilitando etapas posteriores de segmentação e identificação dos alvos de interesse. Uma vez os objetos de interesse estando isolados do restante da imagem, obtendo assim, uma imagem binária, onde é atribuído o valor 1 para os pixels do alvo de interesse, e o

valor 0 para os pixels do restante da imagem, é possível mascarar a imagem original, mantendo assim, apenas os pixels do alvo de interesse. Uma estratégia que pode ser utilizada, é a partir de uma imagem classificada, aplicar uma binarização por meio da reclassificação da imagem, onde classes que compõem o alvo de interesse sejam rotuladas como 1, e o restante como 0, para que possam ser descartadas na análise. De acordo com Aljahdali, Eltawil e Qahwaji (2018), a geração de imagens binárias a partir de sensores RGB, por meio de limiares baseados em canais de cor ou índices como o Excesso de Verde (ExG), tem se mostrado eficaz na separação entre a cultura de interesse e as espécies invasoras, possibilitando o desenvolvimento de sistemas automatizados de detecção e manejo.

Além de técnicas de classificação, no processamento digital de imagens, as imagens processadas, ou os valores obtidos delas, também podem ser utilizados para inferir processos ou outros fenômenos, indiretamente, por meio de técnicas de regressão. Em culturas de batata, Duarte-Carvajalino et al. (2018) aplicaram técnicas de regressão em imagens de UAV para avaliar a severidade da requeima tardia, comprovando a aptidão da técnica para monitoramento confiável em campo. Além de auxiliar na quantificação da severidade de doenças, segundo Pansera (2021), as técnicas de regressão apresentaram resposta positiva ao serem usadas para quantificar a necessidade de adubações de nitrogênio em grãos de aveia, evidenciando a aplicação dessas técnicas.

2.3. Inteligência Artificial na Agricultura

A aplicação de Inteligência Artificial (IA) na agricultura tem ganhado destaque, especialmente em atividades que demandam o processamento de grandes volumes de dados, como o monitoramento de plantas daninhas (HUANG et al., 2018). Dentro da IA, o aprendizado de máquina (*Machine Learning*) é uma das abordagens mais utilizadas, sendo definido por Mitchell (1997) como um campo que dá aos computadores a capacidade de aprender a partir de dados. Entre os algoritmos mais aplicados na agricultura estão as Redes Neurais Artificiais (RNA), as Máquinas de Vetores de Suporte (SVM), as Árvores de Decisão (KAMILARIS; PRENAFETA-BOLDÚ, 2018) e as florestas aleatórias (ou no inglês, Random Forest) (BREIMAN, 2001). Aprendizado de máquina (AM) é uma das subáreas da IA que surgiu com o propósito de "melhorar a si mesmas". Para isso, estuda a construção de algoritmos que possibilitam que programas de computador melhorem seu desempenho automaticamente à medida que são fornecidos novos exemplos de entrada (MONARD; BARANAUSKAS, 2003). Muitos sistemas são desenvolvidos com o objetivo de usufruir dessa capacidade de

aprendizagem. Sendo destaque para tarefas a extração de dados, onde os algoritmos de AM são utilizados para identificar padrões em grandes volumes de dados (FACELI et al., 2011).

Um dos algoritmos mais utilizados para a classificação de imagens de dados agrícolas é o Random Forest (RF), que é um algoritmo de aprendizado de máquina que combina múltiplas árvores de decisão independentes para realizar previsões (BELGIU; DRĂGU, 2016). O RF tem sido utilizado na agricultura para diversos fins, como para otimização da irrigação (PREITE; VIGNALI, 2024), para predição de produtividade de culturas (JHAJHARIA; MATHUR, 2023) e para diferenciação entre plantas daninhas e plantas de interesse (GAO et al., 2018), sendo conhecido por ser capaz de analisar grandes volumes de dados com múltiplas colinearidades com boa precisão (BELGIU; DRĂGU, 2016).

Pesquisas recentes, como as de Silva (2024), e Verçosa et al. (2022), demonstram a eficácia da combinação entre imagens obtidas por drones e algoritmos de aprendizado de máquina na identificação de plantas daninhas em diversas culturas agrícolas. Contudo, a aplicação dessas técnicas especificamente em bananais ainda é pouco explorada, o que reforça a relevância científica e a busca por respostas do presente trabalho.

3. MATERIAL E MÉTODOS

3.1 Localização da Área

O experimento prático foi realizado na Faculdade de Ciências Agrárias do Vale do Ribeira (FCAVR), que é localizada na cidade de Registro – São Paulo, unidade Campus Fazenda Agrochá. O local conta com um bananal próprio, separado em dois talhões e com tamanho de 1 hectare (Figura 3). Atualmente há duas variedades de banana, Prata Hayashi, variedade da *Musa acuminata* e Nanica Williams, que é um grupo derivado da Cavendish.

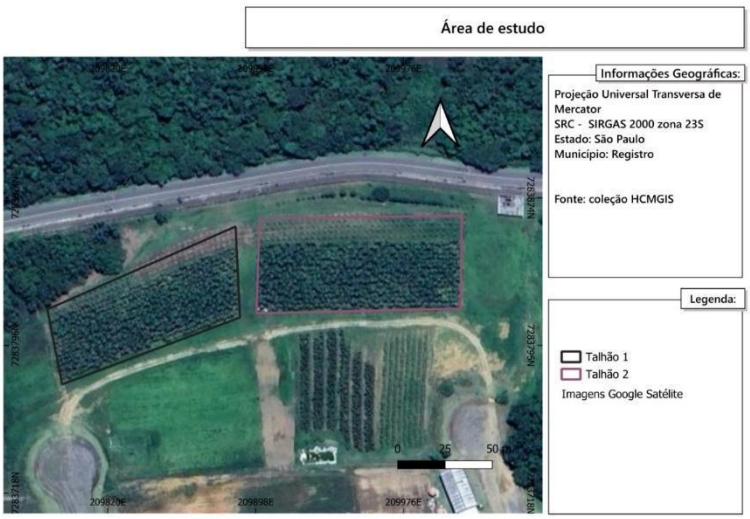

Figura 3 – Mapa da área onde o estudado foi realizado. A seta aponta para o ponto cardeal Norte. Fonte: Autor.

3.2 Materiais

Para realizar o trabalho de pesquisa foram usados o seguinte material: GPS Garmin, disponibilizado pela própria faculdade, o aparelho foi o acessório utilizado para a coleta dos pontos de controle e amostragem, além disso, possibilitou o georreferenciamento das imagens, através do uso das coordenadas geográficas, como longitude e latitude. O drone utilizado para o experimento foi o Mavic Air, da DJI, equipado com uma câmera RGB de 1/1.3” CMOS (*Complementary Metal-Oxide-Semiconductor*), com resolução de até 48 MP. O equipamento pesa em média 450 gramas. Uso do software QGIS Desktop 3.40.6, para realizar o georreferenciamento das imagens, juntamente com o GPS (*QGIS Development Team*, 2025). Os softwares Weka 3.8.6 (FRANK et al 2016), para auxiliar a interpretação dos dados obtidos e o Excel, para gerar gráficos de fácil compreensão.

3.3 Desenvolvimento Metodológico

As atividades iniciais foram desenvolvidas seguindo a ordem da Figura 4.

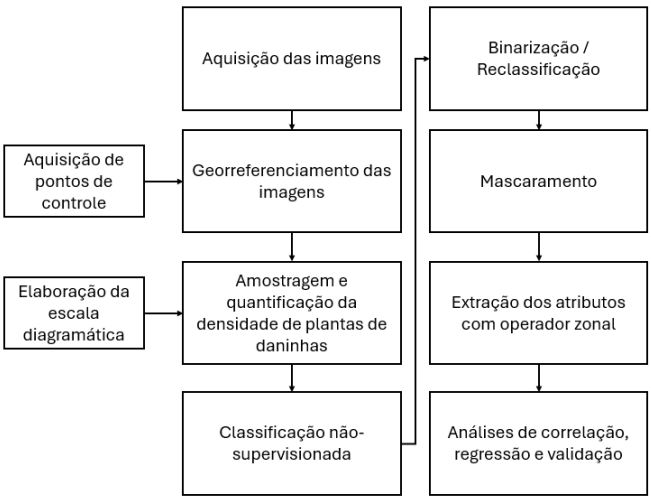

Figura 4 –Diagrama da metodologia. Fonte: Autor.

A seguir cada etapa será descrita em uma subseção.

3.3.1 Aquisição das Imagens

As imagens foram adquiridas com o uso do drone DJI Mavic Air. O voo foi realizado dia 26/04/2025, às 10:00 horas da manhã, em uma altura de 50 metros, coletando imagem dos dois talhões da área estudo, como exibido na Figura 5. As imagens foram obtidas com uma câmera RGB, o que permitiu a análise do brilho das imagens sobre as áreas cultivadas e das plantas daninhas presentes nos bananais.

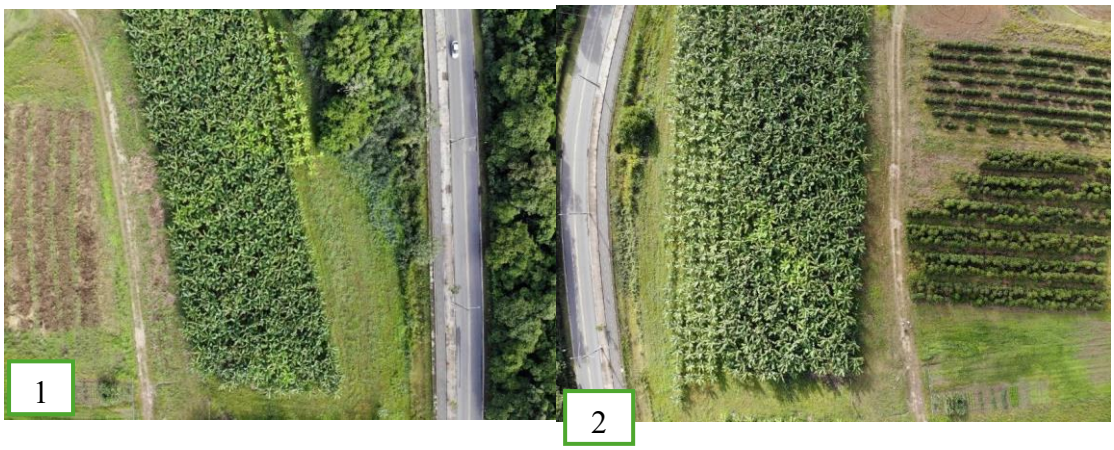

Figura 5 – Imagens obtidas com o sobrevoo do drone DJI Mavic Air, as 10:00 horas manhã, em Registro – SP, dia 26/04/2025. As imagens coletadas são referentes aos dois talhões estudados, o talhão 1 a esquerda e o talhão 2 a direita. Fonte: Autor.

3.3.2. Georreferenciamento das Imagens

Após a coleta das imagens, foi necessária a etapa de georreferenciamento das imagens, também conhecida como registro de imagens. Essa etapa foi marcada por coletar os pontos de controle, com auxílio do GPS. Prosseguimos com a coleta na área representada pela Figura 1, e foram coletados 21 pontos no total (Figura 6 e 7). Os pontos de controle têm a finalidade de subsidiar o processo de georreferenciamento das imagens. A ideia é selecionar pontos como as bordas dos talhões e outros de fácil identificação na imagem, como árvores ou estruturas, para que esses pontos de coordenadas correspondam à mesma região física da imagem a ser registrada. A coleta foi realizada dia 26/04/2025, no momento do sobrevoo.

Figura 6 – Pontos de Controle (em azul) sob o mosaico de imagens de satélite disponível via Google Satélite, visualizada no software QGIS. Fonte: Autor.

Figura 7 – Pontos de Controle (em azul) – Imagens coletadas via drone e georreferenciadas com os pontos de controle, relacionadas ao voo que ocorreu ao longo da área de estudo, em uma altura de 50 metros. Fonte: Autor.

O georreferenciamento das imagens nem sempre apresenta precisão absoluta, o que decorre de algumas variáveis, sendo uma delas o GPS que está sendo utilizado para coleta das

coordenadas e sua precisão, o que pode variar também com a cobertura de nuvens no dia. Em decorrência desse fator, as Tabelas 1 e 2 demonstram o erro obtido em número de pixels, para cada ponto de controle georreferenciado. Esses pixels residuais são estimativas de quantos pixels podem estar distorcidos geometricamente para cada ponto. Obteve-se o erro médio de 6 metros para cada ponto, considerando a quantidade de pixels residuais, multiplicados por 6 cm, que é o tamanho de cada pixel.

Tabela 1 – Quantidade de pixels residuais para cada ponto de controle. Pontos relacionados ao talhão 1. Esses valores são calculados com base nos vetores de georreferenciamento.

Pontos	Pixels Residuais	Distância em Metros
0	40,62	2,44
1	37,35	2,24
2	44,71	2,68
3	110,56	6,63
4	110,93	6,65
5	40,61	2,44
6	107,23	6,44
7	120,91	7,25

Tabela 2 – Quantidade de pixels residuais para cada ponto de controle. Pontos relacionados ao talhão 2.

Pontos	Pixels Residuais	Distância em Metros
0	195,30	11,72
1	44,73	2,68
2	115,37	6,92
3	179,23	10,75
4	252,41	15,14
5	29,62	1,78
6	154,56	9,27
7	25,78	1,54
8	123,53	7,41
9	154,94	9,30
10	189,60	11,38
11	63,21	3,79
12	117,73	7,06

3.3.3 Escala de Fotos e Amostragem

Os pontos de amostragem foram coletados para medir a densidade de plantas daninhas no campo, com um total de 20 pontos, sendo 10 em cada talhão, conforme ilustrado na Figura 8. Para estabelecimento da unidade de amostra, foram selecionados quadrados de 100 m² (10m x 10m), centralizando o GPS no centroide do quadrado, buscando a maior variabilidade de níveis de infestação, com diferentes densidades de plantas daninhas, considerando toda a área estudada.

Esses quadrados foram definidos a partir de buffers, ilustrados na Figura 9, gerados para cada amostra, considerando o ponto central coletado com o GPS. A criação dos buffers é uma técnica que auxilia a delimitar a região de estudo e facilita a captação de componentes da área, como no caso do estudo, a densidade das plantas daninhas. Os quadrados apresentam raio de 5 metros de comprimento.

Figura 8 – Pontos de Amostra (em vermelho). Imagens coletadas via drone, relacionadas ao voo que ocorreu ao longo da área de estudo, em uma altura de 50 metros. Fonte: Autor.

Figura 9 – Buffers para delimitação da área amostrada e extração de atributos da imagem. Fonte: Autor.

As escalas de fotos são utilizadas na orientação de uma estimativa visual de tal modo que a avaliação se torne mais precisa e acurada após a comparação da amostra com a representação na escala. Quando a avaliação visual é feita sem o auxílio de escalas, o avaliador pode atribuir qualquer valor no intervalo de zero a 100% para a superfície ocupada pelo fenômeno avaliado, podendo ser doenças em folhas ou frutos, ou o percentual de infestação de plantas daninhas. O uso da escala permite ao avaliador situar sua estimativa num intervalo menor, compreendido entre dois dos níveis representados por seus diagramas (AMORIM, 1995). A utilização de escalas pode reduzir a subjetividade das estimativas de severidade entre os avaliadores, melhorando a acurácia e a precisão das avaliações (MARTINS et al., 2004).

A escala criada teve como base os focos de infestação e densidade de plantas daninhas presentes na área estudada. Ela foi criada e utilizada para que houvesse a diminuição da taxa do erro durante o período de avaliação, e para que os avaliadores de infestação pudessem dar notas com base em parâmetros reais estudados e definidos. A escala foi criada no dia 16/04/2025 (Figura 10).

O voo e a avaliação da densidade de plantas invasoras foram realizados no mesmo dia, para que ambos os dados estivessem sob a mesma condição climática e vegetativa, pois avaliações em dias diferentes poderiam sofrer com interferência de condições climáticas ou antrópicas, evidenciando que em caso de divergência entre drone e análise visual seja meramente ao acaso.

Figura 10 – Escala de Fotos. Desenvolvida para a quantificação de daninhas presentes na área de estudo. Fonte: Autor.

3.3.4. Classificação Não Supervisionada

A classificação não-supervisionada ou agrupamento não supervisionado foi realizado como a primeira etapa para a remoção das folhas da imagem. Ela foi realizada utilizando o algoritmo k-médias, implementado no QGIS por meio do plugin *Unsupervised Classifier.* Este plugin oferece uma interface fácil de usar para carregar imagens e selecionar entre uma variedade de métodos de classificação não supervisionados, incluindo K-médias. Basta o usuário definir o número de clusters esperado, e selecionar a imagem e as respectivas bandas a serem utilizadas. No nosso caso, foi selecionado empiricamente, balizado por uma avaliação visual, o número de 5 clusters. Essa técnica consiste em procurar os padrões que as folhas de bananeira e as plantas daninhas apresentam, por meio do comportamento do brilho dos pixels da imagem em cada banda RGB, e com isso é possível formar os clusters (grupos). Posteriormente, a identificação do significado das classes foi feita de forma visual e manual, rotulando cada classe, ao observar se ela se referia a área das folhas de bananeira, ou não.

3.3.5 Binarização

Após a classificação não-supervisionada, a binarização foi realizada. A imagem foi separada em cinco classes, de zero a quatro, a partir da aplicação do algoritmo k-médias. E na etapa de binarização, a ideia é agrupar essas classes obtidas na etapa anterior em apenas duas classes: classe zero (cor preta) e classe um (cor branca). A binarização foi realizada por meio de uma reclassificação, onde as classes as quais observou-se que eram correspondentes as folhas de bananeira, foram reclassificadas para classe zero, e as classes correspondentes as áreas sem folhas de bananeira, foram reclassificadas para classe um. Esse procedimento foi realizado a ferramenta de Calculadora Raster, disponível no QGIS.

3.3.6 Mascaramento

Com a binarização realizada, a etapa de conclusão do processo é o mascaramento da imagem original, que consiste na multiplicação da imagem binária pela imagem original. Como a imagem binária (agora, chamada de máscara), possui o alvo de interesse (áreas sem folhas de bananeira) compostas por pixels com valor 1, ao multiplicá-la pela imagem original, estes alvos serão mantidos na imagem resultante, e o que é multiplicado por zero (cor preta, representando as folhas de bananeira), será removido da imagem final. Diante disso, é possível remover as

folhas das bananeiras da imagem e extrair apenas os dados gerados pela densidade de plantas daninhas, ou ausência delas, na área não ocupada pelas folhas.

3.3.7 Extração dos Atributos com Operador Zonal

Posterior à binarização, aplicou-se então o operador zonal, disponibilizado pelo software QGIS, para extrair os valores dos pixels das imagens e então gerar a tabela de atributos. Considerou-se como experimento, a análise das imagens tanto com as folhas removidas pelo processo anterior, quanto com as imagens originais, ou seja, ainda contendo as folhas de bananeira. A ideia foi analisar se com a remoção das folhas nas imagens, seria possível melhorar a correlação dos valores dos pixels das amostras com a densidade de plantas daninhas, uma vez removendo o efeito dos pixels correspondentes ao dossel. Para isso, extraíram-se as seguintes variáveis: média, mediana e variância, cada uma delas aplicadas para as três bandas RGB.

3.4 Modelagem e Análise dos Resultados

A princípio foi realizada uma análise exploratória dos dados, com objetivo de identificar se existem correlações entre as variáveis extraídas da imagem com as notas atribuídas em campo. A análise foi feita com base em valores de entrada e saída, os valores de entrada são a média, mediana e variância para cada uma das três bandas, considerando os valores dos pixels contidos na área dos buffers das amostras, e os valores de saída são as médias das notas dadas com base na escala de fotos, para a amostra correspondente. Foram geradas nove colunas de atributos para a imagem completa e nove colunas para a imagem com as folhas removidas (mascarada). A partir disso foi possível realizar uma análise de correlação de cada variável com a nota final.

Com o objetivo de testar se seria possível construir um modelo capaz de estimar a densidade de plantas daninhas, no bananal analisado, a partir dos atributos extraídos da imagem, considerando uma abordagem multivariada, foi utilizado um algoritmo de aprendizado de máquina chamado Random Forest (BREIMAN, 2001), disponível no software do Weka. Esse algoritmo é muito utilizado para problemas de regressão. Para o treinamento do modelo foram consideradas 100 árvores, e o parâmetro de profundidade máxima da árvore foi configurado de acordo com o padrão do software. O modelo utilizou 66% dos dados para treinamento e 33% para teste. Essa modelagem combina as saídas de várias árvores de decisão para identificar e selecionar os atributos mais relevantes, a fim de alcançar um único resultado para solucionar

problemas de regressão e classificação (CHAROEN-UM et al., 2019). Foram gerados dois modelos, considerando os dois conjuntos de dados, sendo eles, os atributos extraídos da imagem original, e mascarada (ou seja, com as folhas de bananeira removidas da imagem). As acurácias dos modelos foram obtidas pelo coeficiente de correlação (r) e a Raiz Quadrada do Erro Médio (RMSE).

4. RESULTADOS E DISCUSSÕES

Os resultados obtidos com a avaliação em campo para quantificar a densidade das plantas daninhas com base na escala de fotos, são compostos pela média das notas que os três avaliadores deram para cada ponto amostragem, a escala de fotos foi utilizada para diminuir a subjetividade das avaliações visuais. A atribuição de notas foi realizada por 3 avaliadores diferentes com o objetivo de reduzir a subjetividade da análise e eliminar viés. Os pontos de amostragem e a média das respectivas notas, atribuidas pelos avaliadores, são representados na Tabela 3 e 4.

Tabela 3 – Identificadores das amostras correspondentes ao talhão 1 e respectivas médias das notas de densidade de plantas daninhas atribuídas pelos avaliadores.

Pontos Coletados	Média das Notas
22	6,83
23	3,67
24	5,67
25	5,67
27	5,5
28	4,17
29	4,00
31	4,33
33	6,33
34	8,00

Tabela 4 – Identificadores das amostras correspondentes ao talhão 2 e respectivas médias das notas de densidade de plantas daninhas atribuídas pelos avaliadores.

Pontos Coletados	Média das Notas
35	2,00
36	2,00
37	2,83
38	3,17
39	4,17
40	4,33
41	3,65
43	5,50
44	5,33
45	2,50

Observa-se que as notas variaram entre 2,00 e 8,00, com média de 4,45 e mediana 4,25. A escala foi desenvolvida considerando a variação máxima observada no campo, no entanto,

não ocorreram amostras com 0% ou 100% de presença de daninhas, a miníma ocorrência de foi de 20% e a máxima de 80%, seguindo a escala de fotos.

A Figura 11 apresenta uma amostra de imagem com o resultado da classificação não-supervisionada utilizando o algoritmo k-médias, considerando 5 classes.

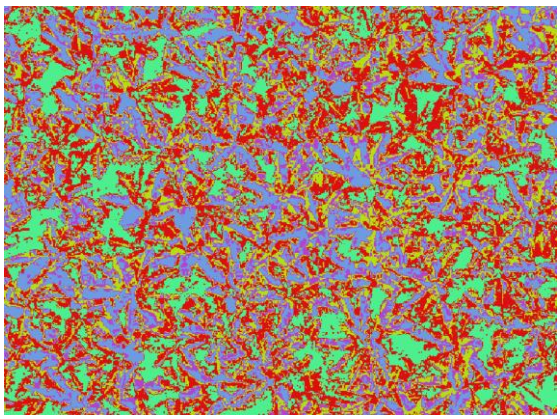

Figura 11 – Resultado da aplicação do algoritmo K-médias, para separar a imagem em 5 classes diferentes. Fonte: Autor.

A Figura 12 ilustra um exemplo de como foi feita a rotulação das classes obtidas pelo processo, identificando as classes que continham majoritariamente pixels correspondentes as folhas das bananeiras, e as que continuam maior presença de elementos do fundo, como solo exposto, plantas daninhas, sombra do dossel e palhada.

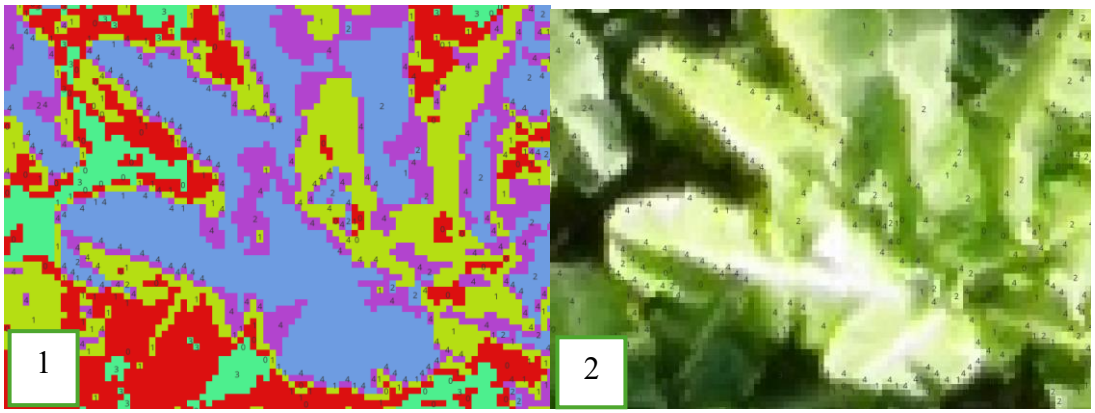

Figura 12 – 1) Resultado da aplicação do algoritmo k-médias para a separação da imagem em 5 classes diferentes (de zero a quatro). 2) Imagem original, com os números das classes obtidas automaticamente, sobre as respectivas feições na imagem, ilustrando o processo de rotulação visual. Fonte: Autor.

Visualmente observou-se que as classes 0 e 1 correspondiam majoritariamente às áreas sem folha, enquanto as classes de 2, 3 e 4, às folhas de bananeira.

Finalmente, após a reclassificação foi possível obter a imagem binária que foi utilizada no processo de mascaramento da imagem original. As classes foram agrupadas entre classe zero (cor preta) e classe 1 (cor branca), demonstradas na Figura 13.

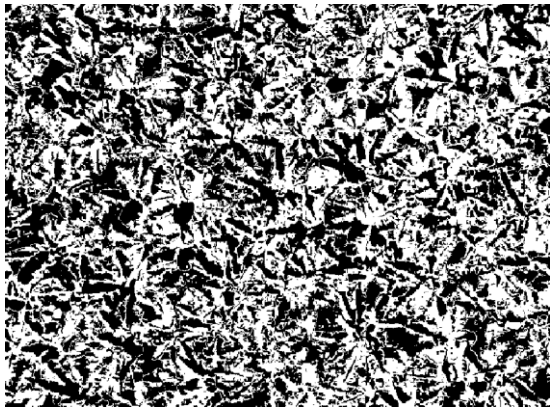

Figura 13 – Imagem binária, que posteriormente foi utilizada para o processo de mascaramento. Fonte: Autor.

Conforme ilustrado na Figura 14, com a binarização completa, foi realizado o mascaramento da imagem original, onde foi possível separar o alvo de interesse, no caso as plantas daninhas, e a separação do que poderia distorcer a avaliação da densidade, as folhas de bananeira.

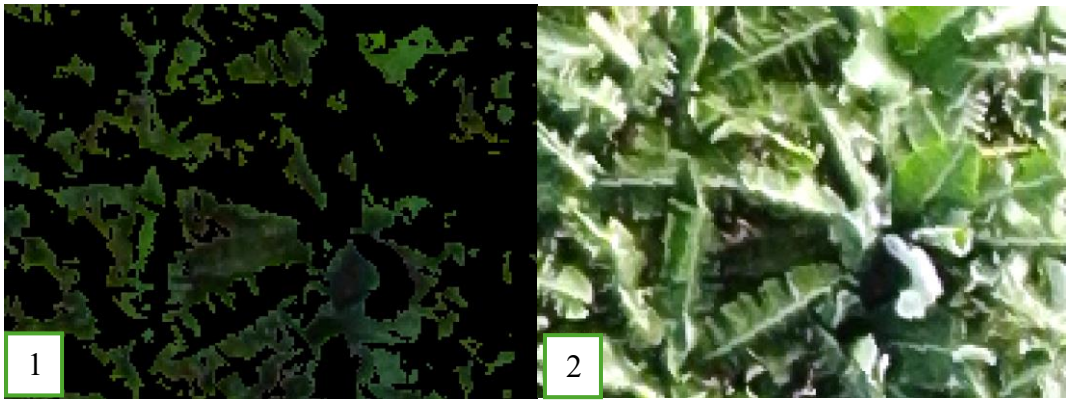

Figura 14 – 1) Imagem mascarada, sem a presença de folhas de bananeiras. 2) Imagem completa do bananal, para facilitar a compreensão do mascaramento. Fonte: Autor.

Pode-se observar, que as áreas da imagem remanescentes após o mascaramento apresentam uma tonalidade mais escura, por conta do efeito do sombreamento, mas em algumas

áreas ainda é possível observar a presença do extrato herbáceo no fundo, assim como, mesmo nas áreas sombreadas, é possível obter alguma informação do brilho da imagem. A hipótese do trabalho foi de que se porventura haja a presença de plantas daninhas, algum sinal na imagem poderia refletir isso, sobretudo, uma maior variabilidade nos valores quando com uma maior densidade de plantas daninhas.

As Tabelas A1 e A2, apresentadas no Apêndice A, apresentam os valores de cada atributo, que foram extraídos com auxílio do operador zonal, respectivamente para as imagens originais e mascaradas. Elas são compostas por uma coluna com a numeração dos pontos de amostragem coletados e nove colunas dos dados estudados, para todas as bandas. A nomenclatura foi dividida da seguinte forma: a letra "b" refere-se a banda, os números 1, 2 e 3 são para definir qual a banda (RGB) é, 1 – banda vermelha, 2 – banda verde e 3 – azul, a letra "c" presente na nomenclatura demonstra que os dados são provenientes da amostra com folha, já a letra "s" demonstra que os dados são provenientes da amostra sem folha. Os dados estão distribuídos sequencialmente em média, mediana e variância sucessivamente para cada uma das bandas.

Com os dados obtidos nas Tabelas A1 e A2, foi possível correlacionar esses valores de entrada com os valores de saída. O coeficiente de correlação é descrito pela letra "r", e demonstra se há alguma relação linear dos pontos no gráfico. As Tabelas 5 e 6 demonstram esse coeficiente de correlação.

Tabela 5 – Correlação entre os atributos extraídos pelo operador zonal e as médias das notas com base na escala de fotos, imagem com folhas de bananeira.

Atributos	Correlação
_b1c_média	0,26
_b1c_mediana	0,17
_b1c_variância	0,38
_b2c_média	0,06
_b2c_mediana	0,01
_b2c_variância	0,29
_b3c_média	0,37
_b3c_mediana	0,10
_b3c_variância	0,46

Tabela 6 – Correlação entre os atributos extraídos pelo operador zonal e as médias das notas com base na escala de fotos, imagem sem as folhas de bananeira.

Atributos	Correlação
_b1s_média	0,09
_b1s_mediana	0,03
_b1s_variância	-0,05
_b2s_média	-0,16
_b2s_mediana	-0,19
_b2s_variância	-0,53
_b3s_média	-0,06
_b3s_mediana	-0,14
_b3s_variância	-0,21

De acordo com a Tabela 5, o atributo do operador zonal que mais se correlacionou com as notas, foi o da variância da Banda 3 (Azul).

Conforme apresentado na Tabela 6, o atributo que mais se correlacionou com as notas, foi o da variância da Banda 2 (Verde), mesmo que apresente uma correlação negativa, é possível concluir que os dados são variáveis inversamente proporcionais, à medida que uma dessas variáveis sobe, a outra irá descer, demonstrando que há correlação entre elas.

A Figura 15 apresenta o gráfico de dispersão entre a variância da Banda 3 (eixo y) extraída pelo operador zonal e as notas atribuídas a campo (eixo x) com auxílio da escala de fotos.

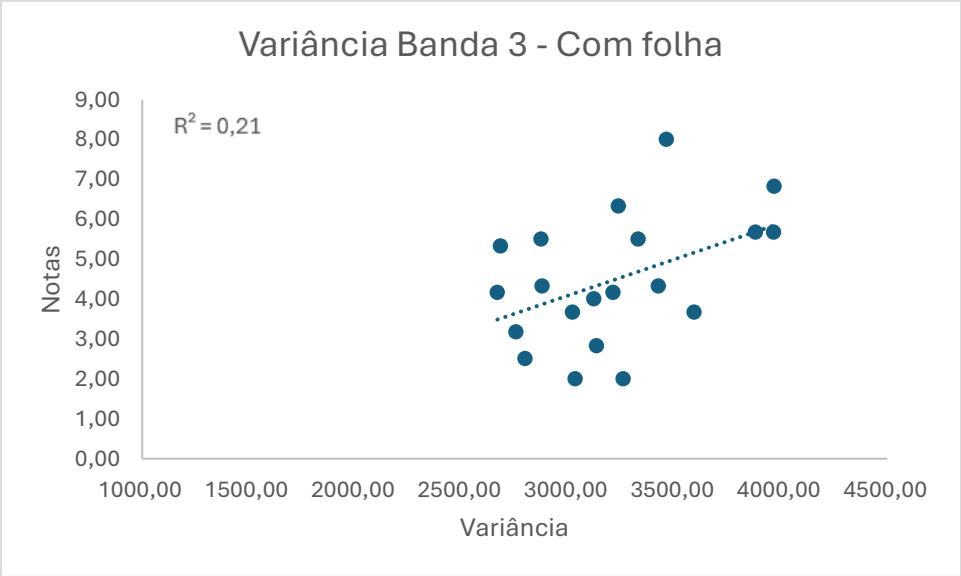

Figura 15 – Gráfico de dispersão entre a variância da banda 3 e sua correlação com as notas. Com folha de bananeira. Fonte: Autor.

A Figura 16, demonstra a dispersão entre a variância da Banda 2, em relação com as notas atribuídas a campo.

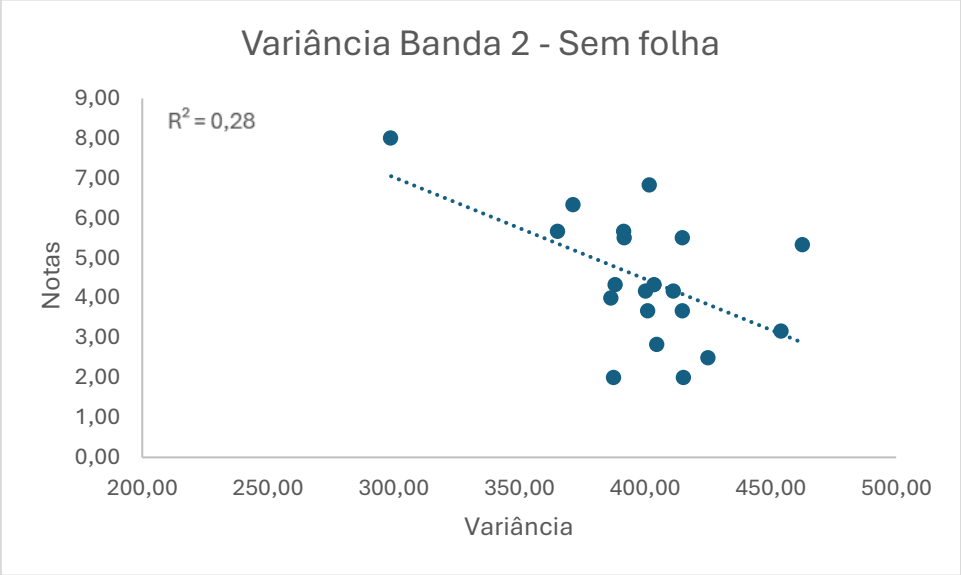

Figura 16. Gráfico de dispersão entre a variância da banda 2 e sua correlação com as notas. Sem folha de bananeira. Fonte: Autor.

A partir das variáveis com maiores correlações analisadas em relação as notas relacionadas a intensidade de plantas daninhas nas áreas, observou-se que existe uma correlação moderada, com os valores de variância nas bandas do verde (banda 2) e azul (Banda 3). A banda verde possui uma correlação positiva com às notas, considerando os atributos extraídos das imagens originais (com presença de áreas do dossel do bananal), indicando, que quanto maior a variância dos pixels nessa banda, maior a densidade de plantas daninhas no bananal analisado. Por outro lado, a variância na banda azul (banda 3) possui uma correlação moderada negativa, indicando que quanto menor a variância observada nesta banda, maior a densidade de plantas daninhas.

A partir de testes empíricos, e com base na literatura científica, considerou-se o algoritmo Random Forest para realização de um exercício de modelagem, com objetivo de analisar o potencial de se estimar indiretamente, por meio da imagem de drone, a densidade de plantas daninhas no bananal analisado. Conforme descrito na metodologia, foram considerados os dois conjuntos de dados (obtidos a partir das estatísticas extraídas da imagem mascarada e da imagem original), e para ambos, foi realizado um teste, considerando a abordagem de validação "*Percentage split*", onde 66% das amostras são utilizadas para treinamento, e a validação realizada com os 33% remanescentes, utilizando o software Weka.

A Tabela 7 apresenta os resultados obtidos por meio das métricas de coeficiente de correlação e Raiz Quadrada do Erro Médio (RMSE), considerando os dois conjuntos de dados.

Tabela 7. Resultados obtidos por meio das métricas de coeficiente de correlação e Raiz Quadrada do Erro Médio (RMSE), considerando os dois conjuntos de dados, utilizando o algoritmo Random Forest.

	Coeficiente de Correlação (r)	**Raiz Quadrada do Erro Médio (RMSE)**
Imagem mascarada (sem folhas)	0,52	0,99
Imagem original (com folhas)	-0.26	1.49

Conforme apresentado na Tabela 7, é possível observar que o modelo Random Forest considerando o conjunto de dados obtido da imagem mascarada (sem folhas), obteve um menor RMSE e um maior coeficiente de correlação, indicando uma maior capacidade de estimar a densidade de plantas daninhas, embora segundo Rumsey (2023) o coeficiente aproximado de 0,50 represente uma correlação moderada. Tal resultado, corrobora com a hipótese inicial do trabalho, uma vez que era esperado que ao remover a influência das folhas de bananeira na imagem, poderia ser observada uma melhora na capacidade de se correlacionar valores extraídos da imagem com a densidade de daninhas no campo.

Para demonstrar a aplicação do modelo, foi obtido um modelo médio considerando o particionamento dos dados descrito acima, iterado 100 vezes, para garantir uma maior aleatoriedade. Este modelo, treinado apenas com 66% dos dados, foi aplicado no conjunto total das amostras, e o resultado é apresentado na Figura 17.

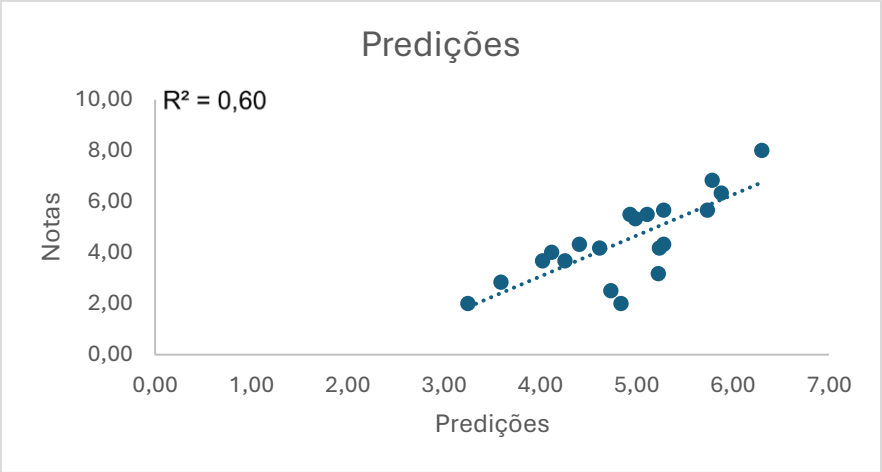

Figura 17. Gráfico de dispersão obtido a partir das predições do modelo médio do Random Forest, treinado com 66% dos dados, aplicado ao conjunto total das amostras, e os dados reais obtidos pelos avaliadores no campo. Fonte: Autor.

É possível observar um (R^2) de 0,60, considerado moderado, sendo que cerca de 15% dos dados não apresentaram um bom ajuste. Não foi investigado o comportamento isolado destes outliers para levantar hipóteses sobre este comportamento.

Porém, apesar de ser um estudo preliminar, em uma área limitada, disponível para a realização do experimento, que resultou em uma quantidade mínima de amostras, a estimativa moderada, mesmo que não seja conclusiva, encoraja a investir em trabalhos futuros nesta linha, pois a banana além de apresentar grande expressão agrícola mundial, as daninhas continuam sendo um desafio para a cultura, e manejá-las de forma correta além de diminuir o custo de aplicação com defensivos e preservar o meio ambiente, pode impactar de forma direta na produção do bananal.

Outro fator importante de ser considerado na avaliação dos resultados, é, além do baixo número de amostras, o GPS Garmin, que foi utilizado para coleta dos pontos de controle ao longo do experimento não apresenta elevada precisão, podendo deslocar o ponto coletado entre 1 a 3 metros, algo que impactou diretamente a extração de valores para atributo analisado, esses fatores aliados ao erro médio obtidos durante a etapa de registro da imagem, é possível estimar um valor médio de 6 metros entre a posição coletada a campo e as coordenadas que foram processadas no QGIS.

Considerando a área amostrada, como um quadrado de 10 por 10 metros para extração de atributos e avaliação, imagina-se que o erro médio obtido pelo registro das imagens, possa

impactar de forma negativa para a obtenção de resultados mais assertivos ao longo do processamento das imagens, uma vez que áreas adjacentes, com diferentes níveis de densidade de plantas daninhas, possam estar sendo consideradas. Idealmente, para alcançar resultados mais precisos, seria interessante a utilização de um GPS geodésico, que permitiria a obtenção de uma precisão centimétrica no registro da imagem, essa elevada precisão pode ser obtida com o uso do GPS RTK (*Real Time Kinematic*).

Além disso, a classificação não-supervisionada utilizada no trabalho, é passível de erros inerentes do processo, pois é possível que inclua margens das folhas de bananeira do dossel, folhas do baixeiro, ou até mesmo folhas que foram podadas e se encontram postas ao solo, impactando diretamente nos valores de variância obtidos pelo operador zonal. Para que seja possível aumentar a taxa de sucesso de separação correta da imagem, seria a utilização de drones mais robustos, com melhor qualidade de sensores sendo eles multiespectrais com banda do infravermelho, pois mais bandas poderiam ser exploradas, o que possivelmente facilitaria a separação da cultura de interesse e as daninhas. Além disso, a utilização de métricas de textura, como dissimilaridade, contraste, entropia e homogeneidade, extraídas da matriz de co-ocorrência de níveis de cinza (*Gray-Level Co-occurrence Matrix* – GLCM), descritas por Haralick et al (2007), poderia agregar na análise por serem medidas de textura locais, menos suscetíveis a presença de valores espúrios na imagem, como no caso da variância. Outros autores relataram a importância da utilização dessas métricas em trabalhos para identificação de plantas daninhas (PHAM et al., 2024).

Outros trabalhos desenvolvidos com objetivo de identificar plantas daninhas utilizando imagens de drone obtiveram melhores resultados, uma vez que na maioria deles, trata-se de culturas anuais, em problemas onde o objetivo era identificar a planta, ainda na fase de pré-emergência. Desta forma, a tarefa do classificador consistia na maioria das vezes em separar plantas de folha larga e folha estreita, ou então, separar as plantas daninhas do fundo, que consistia em solo exposto ou palhada unicamente, diminuindo a complexidade. No presente trabalho, diferentemente, trata-se de uma cultura perene, de modo que na maior do ciclo irá apresentar um dossel com grande cobertura da área, sendo a análise limitada a regiões da entrelinha das plantas onde é possível obter uma resposta do fundo, mas que, porém, influenciada pela sombra das folhas e mesmo outras folhas do baixeiro. Para nosso conhecimento, não existe na literatura nenhum trabalho similar, sendo assim, este trabalho reflete um avanço na pesquisa nesta área, indicando uma metodologia que pode ser melhorada, ou adaptada para estudos futuros, uma vez que por não ter base de outros estudos relacionados

com esse, o experimento foi um teste para analisar a possibilidade de quantificar daninhas seguindo metodologias que apresentaram sucesso em outras literaturas e com outras culturas.

Uma alternativa interessante que deve ser explorada também para aumentar a quantidade de dados para comparação, seria uma coleta de amostras mais expressiva e em uma área maior, para que haja maior variação de dados. Além disso, voos em outra estação do ano poderiam ser uma opção viável, uma vez que as daninhas se comportam de forma diferente de acordo com cada estação do ano (EMBRAPA, 2003).

5. CONCLUSÃO

Diante dos resultados apresentados, observou-se que a correlação entre os dados obtidos pelo operador zonal e as notas atribuídas a campo, foi de -0,26 para as imagens completas, enquanto a mesma análise para a imagem sem as folhas de bananeira, resultou em uma correlação de 0,52, valor que demonstra relação moderada entre os dados.

Ao utilizar o modelo treinado com os dados parciais, para realizar uma predição no conjunto total dos dados, observou-se um coeficiente de determinação (R^2) de 0,60.

Em suma, o uso de imagens de drone com câmera RGB não apresentou resultado satisfatório com precisão da estimativa da densidade de plantas daninhas em bananais.

Entretanto, com a remoção das folhas de bananeira das imagens, essa correlação de dados aumenta, demonstrando que há uma relação entre os dados, encorajando o desenvolvimento de trabalhos futuros.

6. REFERÊNCIAS BIBLIOGRÁFICAS

A. K. JAIN, "**Data clustering: 50 years beyond Kmeans**", in Pattern Recognit. Lett., vol. 31, no 8, 2010, p. 651–666. [2] S. P. Lloyd, "Least squares quantization in {PCM}. Special issue on quantization", in IEEE Trans. Inf. Theory, vol. 28, no 2, 1982, p. 129–137.

ALJAHDALI, H.; ELTAWIL, A.; QAHWAJI, R**. Vegetation segmentation from UAV RGB imagery using thresholding techniques**. Sensors, v. 18, n. 5, p. 1722, 2018.

ALMEIDA, C. S. et al. Interferência de plantas daninhas na produtividade da bananeira. Planta Daninha, v. 36, p. e018172968, 2018.

AMORIM, L. **Avaliação de doenças**. In: Bergamin Filho, A., Kimati, H. & Amorim, L. (Eds.). Manual de Fitopatologia v.1. São Paulo. Editora Ceres. 1995. pp.64.

ARANTES, F. et al. Mapeamento de plantas daninhas em mandioca utilizando índices de vegetação. **Revista Brasileira de Agricultura de Precisão**, v. 4, n. 2, p. 45-56, 2019.

ARAÚJO, M. V. A. d. Trabalho de conclusão de curso**, Métodos de Clustering em Aprendizado de Máquinas Não Supervisionado**. Niterói: [s.n.], 2021. Pag 15, 89 f.

BARANAUSKAS, J.A. **Extração automática de conhecimento por múltiplos indutores**. Tese de Doutorado. Instituto de Ciências Matemáticas e de Computação, USP, 2000.

BELGIU, M.; DRĂGUŢ, 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. DOI: https://doi.org/10.1016/j.isprsjprs.2016.01.011. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265?via%3Dihub. Acesso em: 15 jun. 2024.

BREIMAN, Leo**.** Random forests**. Machine Learning**, v. 45, p. 5-32, 2001.

CAO, Y.; WEI, S.; HUANG, H.; LI, W.; ZHANG, C.; HUANG, Z. Target-site mutation and enhanced metabolism confer resistance to thifensulfuron-methyl in a multipleresistant redroot pigweed (Amaranthus retroflexus) population. **Weed Science**, v. 69(2), p. 161-166, 2020.

CHAROEN-UM, N. et al. A review of Random Forest applications in remote sensing and agriculture. **Remote Sensing Letters**, v. 10, n. 3, p. 259–272, 2019.

CHENG, J.; WU, J.; QIANG, H.; ZHOU, B. XU, G.; WANG, Z. Sugarcane nodes identification algorithm based on sum of local pixel of minimum points of vertical projection function. **Computers and Electronics in Agriculture**, v. 182, 105994, 2021.

CHILES, J. P.; DELFINER, P. **Geostatistics**: modeling spatial uncertainty (Vol. 713). John Wiley & Sons, 2012.

CHIVASA, W.; MUTANGA, O.; BURGUENO, J. UAV-based high-throughput phenotyping to increase prediction and selection accuracy in maize varieties under artificial MSV inoculation. **Computers and Electronics in Agriculture**, v. 184, 106128, 2021.

CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. **Machine learning**, v. 20, p. 273-297, 1995.

DUARTE-CARVAJALINO, J. M. et al. Assessing late blight severity in potato using UAV imagery and regression analysis. **Computers and Electronics in Agriculture**, v. 154, p. 115–123, 2018.

EFRON, B.; GONG, G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. **The American Statistician**, Washington, DC, v.37, n.1, p.36-48. 1983.

EMBRAPA. **Manual de manejo de plantas daninhas em culturas perenes**. Brasília: EMBRAPA, 2003.

EMBRAPA. **Prosa Rural** – Manejo integrado de plantas daninhas em bananais. 2010 <Disponível em: https://www.embrapa.br/busca-de-noticias /-/noticia/2422806/prosa-rural---manejo-integrado-de-plantas-daninhas-em-bananais>.Acesso em: 15 jun. 2025.

FACELI, K.; LORENZETTI, C. M.; RABELO, M. A.; SANTOS, R. M. dos. **Inteligência artificial e suas aplicações**. São Paulo: LTC, 2011.

FAO. **Crops and livestock products. Statistic Division**, FAOSTAT, Food and Agriculture Organization of the United Nations. Roma: FAO, 2023. Disponível em: https://www.fao.org/faostat/en/#data/QCL/visualize Acesso em: 16 de jun. de 2024.

FRANK, E.; HALL, M. A.; WITTEN, I. H. **The Weka Workbench**. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques, Morgan Kaufmann, 4. ed., 2016. p. 1-128.

FRIZO, A. **A bananicultura familiar no Vale do Ribeira**: perfil socioeconômico e desafios. Revista de Agricultura Familiar, v. 11, n. 2, p. 25-36, 2015.

GAGO, J.; DOUTHE, C.; COOPMAN, R. E.; GALLEGO, P. P.; RIBAS-CARBO, M.; FLEXAS, J.; MEDRANO, H. UAVs challenge to assess water stress for sustainable agriculture. **Agricultural water management**, v. 153, p. 9-19, 2015.

GAO, J., Nuyttens, D., Lootens, P., He, Y., Pieters, J.G., 2018. Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. **Biosystems Engineering** 170, 39–50. https://doi.org/10.1016/j.biosystemseng.2018.03.006.

GOMES, G. L. G. C. et al. Cadastramento fitossociológico de plantas daninhas na bananicultura. **Planta Daninha**, v. 28, n. 1, p. 61-68, 2010.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3rd ed. Upper Saddle River: Pearson Prentice Hall, 2011.

HARALICK, Robert M.; SHANMUGAM, Karthikeyan; DINSTEIN, Its' Hak. Textural features for image classification. **IEEE Transactions on systems**, man, and cybernetics, n. 6, p. 610-621, 2007.

HASSANEIN, H. et al. A new vegetation segmentation approach for cropped fields based on threshold detection from hue histograms. **Sensors**, v. 18, n. 4, p. 1253, 2018. DOI: 10.3390/s18041253.

HUANG, Y.; REDDY, K.N.; FLETCHER, R.S.; PENNINGTON, D. UAV low-altitude remote sensing for precision weed management. **Weed technology**, v. 32(1), p. 2-6, 2018.

IBGE. **Produção de banana. Instituto Brasileiro de Geografia e Estatística** (IBGE) 2024. Disponível em: https://www.ibge.gov.br/explica/producao-agropecuaria/banana /br Acesso em: 01 de jun. de 2025.

INPE – **Instituto Nacional de Pesquisas Espaciais. Processamento Digital de Imagens de Sensoriamento Remoto.** São José dos Campos: INPE, 2006.

ISAAC, W. P, BRATHWAITE, R. A. I, COHEN, J. E, & BEKELE, I. Effects of alternative weed management strategies on Commelina diffusa Burm. infestations in Fairtrade banana (Musa spp.) in St. Vincent and the Grenadines. **Crop Protection**. vol. 26, p. 1219- 1225, 2007.

JHAJHARIA, K., Mathur, P., 2023. Prediction of crop yield using satellite vegetation indices combined with machine learning approaches. **Advances in Space Research** 72 (9), 3998–4007. https://doi.org/10.1016/j.asr.2023.07.006.

JORGE, L. A. C.; CRESTANA, S. Utilização de técnicas de processamento digital de imagens na agricultura de precisão. **Revista Brasileira de Ciência do Solo**, Campinas, v. 31, n. 5, p. 867–879, 2007. DOI: 10.1590/S0100-06832007000500001.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. **Deep learning in agriculture**: A survey. Computers and Electronics in Agriculture, v. 147, p. 70–90, 2018.

LI, Mingxia; LI, Jiyu. Advances in developments and trends of UAV technology in the context of precision agriculture. **Agriculture, Basel**, v. 15, n. 11, p. 1146, 2025. DOI: 10.3390/agriculture15111146.

LOTTES, P.; STREK, F.; WIESNER, K.; PFEIFFER, D.; STACHNISS, C. Effective weed detection in UAV images using a supervised learning approach. **Computers and Electronics in Agriculture**, v. 140, p. 127–137, 2017.

MACQUEEN, James. **Some methods for classification and analysis of multivariate observations.** In: Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics. University of California press, 1967. p. 281-298.

MAIA, MARÍLIA MAGALHÃES; DE ANDRADE, LUIZA HELENA FELIX; FERNANDES, Silvio. K-means na análise de características socioeconômicas de candidatos ao ensino superior. **Anais do Encontro de Computação do Oeste Potiguar ECOP/UFERSA** (ISSN 2526-7574), v. 2, n. 5, 2021.

MALAMIRI, H. R.G. et al. A study on the use of UAV images to improve the separation accuracy of agricultural land areas. **Computers and Electronics in Agriculture**, v 184, p. 106079, 2021.

MARTINS, M. C.; GUERZONIL, R. A.; CÂMARA, G. M. de S.; MATTIAZZI, P.; LOURENÇO, S. A.; AMORIM, L. Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira**, Brasília, v. 29, n. 2, p. 179-184, 2004.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.
OLIVEIRA, A. C.; SOUZA, J. P. Plantas daninhas hospedeiras de pragas na cultura da banana. **Caderno de Pesquisa UNESP**, v. 21, n. 1, p. 103-110, 2000.

OLIVEIRA, A. J.; DA SILVA, G. F.; SILVA, G. R.; SANTOS, A. A. C.; CALDEIRA, D. S. A.; VILARINHO, M. K. C.; OLIVEIRA, T. C. Potencialidades da utilização de drones na agricultura de precisão. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140- 64149, 2020.

OLIVEIRA, T. R. et al. Diversidade de plantas daninhas em bananais do Vale do Ribeira. **Revista Brasileira de Fruticultura**, v. 39, n. 4, p. e-021, 2017.

PANSERA, V. et al. Modelos de regressão polinomiais na otimização de manejos para a máxima produtividade industrial com qualidade química em grãos de aveia. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021.

PEÑA, J. M.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; CASTRO, A. I. e LÓPEZ GRANADOS, F. Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. **Sensors**, 15(3), 5609-5626, 2015. https://doi.org/10.3390/s150305609.

PHAM, D.; GAUTAM, D.; SHEFFIELD, K. Classifying Serrated Tussock Cover from Aerial Imagery Using RGB Bands, RGB Indices, and Texture Features. **Remote Sensing**, v. 16, n. 23, p. 4538, 2024.

PREITE, L.; VIGNALI, G. Artificial intelligence to optimize water consumption in agriculture: A predictive algorithm-based irrigation management system. **Computers and Electronics in Agriculture**, v. 223, n. 109126, 2024. DOI: https://doi.org/10.1016/j.compag.2024.109126. Disponível em: https://www.sciencedirect.com/science/article/pii/S0168169924005179?via%3Dihub. Acesso em: 25 mar. 2025.

RODRIGUEZ, J.; LiZARAZO, I.; PRIETO, F.; ANGULO-MORALES, V. Assessment of potato late blight from UAV-based multispectral imagery. **Computers and Electronics in Agriculture**, v. 184, p. 106061, 2021.

RUMSEY, D. J. **What is r value correlation? Dummies**, 06 fev. 2023. Disponível em: https://www.dummies.com/article/academics-the-arts/math/statistics/how-to-interpret-a-correlation-coefficient-r-169792/. Acesso em: 11 jul. 2025.

SILVA, J. A. O. S. (2024). **Modelos de aprendizagem profunda para detecção e segmentação de plantas daninhas com imagens obtidas por uav.**

SILVA, T. S.; LIMA, T. V. de; OLIVEIRA, J. V. de; MENEZES, R. S. C.; SANTOS, A. B. dos. **Monitoramento da Sigatoka Amarela em bananais por meio de imagens RGB obtidas por VANT.** Universidade Federal do Ceará, 2020. Disponível em: https://www.freshplaza.com/north-america/article/9200399/monitoring-banana-yellow-sigatoka-by-uav. Acesso em: 30 jun. 2025.

SOUSA, C. A. et al. Nutrição da bananeira e exigências agronômicas. **Revista Brasileira de Fruticultura**, v. 32, n. 1, p. 56–67, 2010.

SURENDRAN, U.; NAGAKUMAR, K. C. V.; SAMUEL, M. P. **Remote sensing in precision agriculture**. In: PRIYADARSHAN, P. M.; JAIN, S. M.; PENNA, S.; AL-KHAYRI, J. M. (Org.). Digital agriculture: a solution for sustainable food and nutritional security. Cham: Springer, 2024. p. 201–223. DOI: 10.1007/978-3-031-43548-5_7.

SUZUKI et al. 2010 TARO SUZUKI, YOSHIHARU AMANO e TAKUMI HASHIZUME. “Vision based localization of a small UAV for generating a large mosaic image”, **Proceedings of SICE Annual Conference 2010**, pgs. 2960 – 29.

VERÇOSA, J. P. D. S. (2022). **Desenvolvimento de algoritmo baseado em redes neurais convolucionais para detecção de ervas daninhas em áreas de cana-de-açúcar.**

YANG, X. et al. A review of remote sensing image processing techniques in agriculture. **Computers and Electronics in Agriculture**, v. 162, p. 284–292, 2019.

YANO, D. S.; BONINI, C. S. B.; SOUZA, L. C.; GONÇALVES, W. N.; FERREIRA, R. S. **Identificação de culturas e plantas daninhas em áreas de cana-de-açúcar utilizando imagens RGB obtidas por VANT**. Research, Society and Development, v. 11, n. 11, e278111111178, 2022. DOI: 10.33448/rsd-v11i11.11178.

ZHANG, JIALI. **Research on Digital Image Processing and Recognition Technology of Weeds in Maize Seedling Stage Based on Artificial Intelligence**. Journal of Physics: Conference Series, v. 1648, 042058, 2020. DOI: 10.1088/1742-6596/1648/4/04205864.

APÊNDICE A. Tabelas com os valores dos atributos extraídos pelo operador zonal (imagem original e mascarada).

Tabela A1. Valores de cada atributo, que foram extraídos com auxílio do operador zonal, para a imagem original.

Pontos	_b1c_média	_b1c_mediana	_b1c_variância	_b2c_média	_b2c_mediana	_b2c_variância	_b3c_média	_b3c_mediana	_b3c_variância	Nota
22	97,71	79,00	5181,33	116,12	102,00	5494,38	73,78	53,00	3970,83	6,83
23	101,97	89,00	4889,43	120,31	111,00	5176,09	72,03	54,00	3594,75	3,67
24	104,68	92,00	4981,15	123,56	116,00	5103,90	74,97	56,00	3883,17	5,67
25	91,14	70,00	4972,09	107,46	92,00	5168,25	71,56	48,00	3966,37	5,67
27	96,22	83,00	4415,78	113,09	104,00	4549,42	69,07	52,00	3331,03	5,50
28	80,58	58,00	4197,39	96,24	79,00	4500,64	63,23	42,00	3212,78	4,17
29	77,58	54,00	4036,80	93,93	75,00	4313,40	60,98	40,00	3121,94	4,00
31	81,95	61,00	4196,15	97,11	82,00	4532,98	67,48	47,00	3425,68	4,33
33	78,57	59,00	3820,47	93,40	78,00	4121,89	65,09	44,00	3238,34	6,33
34	99,11	90,00	3825,16	113,58	107,00	3893,90	78,25	64,00	3464,30	8,00
35	97,99	87,00	3834,94	118,81	112,00	4010,52	75,23	60,00	3261,21	2,00
36	85,63	70,00	3759,54	106,22	97,00	4194,80	68,51	54,00	3035,52	2,00
37	86,03	70,00	3882,42	107,05	97,00	4276,46	66,75	50,00	3134,81	2,83
38	91,17	80,00	3635,70	114,78	110,00	4011,96	66,66	54,00	2755,96	3,17
39	95,51	86,00	3518,26	120,06	116,00	3846,24	65,96	54,00	2668,25	4,17
40	92,03	81,00	3731,23	113,87	108,00	4043,63	68,50	56,00	2880,48	4,33
41	92,88	82,00	3771,91	114,99	109,00	4136,98	69,52	56,00	3021,83	3,67
43	107,40	104,00	3758,93	130,50	132,00	4049,98	73,36	65,00	2873,79	5,50
44	100,54	97,00	3590,93	126,22	127,00	4010,33	70,14	61,00	2684,71	5,33
45	92,28	82,00	3534,74	115,82	111,00	3961,11	69,27	57,00	2799,82	2,50

Tabela A2. Valores de cada atributo, que foram extraídos com auxílio do operador zonal. Os dados correspondem a análise feita na imagem mascarada (sem folha de bananeira).

Pontos	_b1c_média	_b1c_mediana	_b1c_variância	_b2c_média	_b2c_mediana	_b2c_variância	_b3c_média	_b3c_mediana	_b3c_variância	Nota
22	29,42	27	204,14	44,20	42,00	401,95	18,75	17	117,46	6,83
23	32,09	30	213,44	46,81	46,00	401,21	18,49	16	123,70	3,67
24	32,12	30	206,73	47,99	47,00	391,66	18,54	17	118,62	5,67
25	28,87	26	197,73	42,56	41,00	365,42	19,88	18	121,49	5,67
27	31,86	30	215,44	46,26	46,00	391,91	18,47	17	116,41	5,50
28	28,51	26	200,46	41,17	39,00	400,43	20,13	18	126,62	4,17
29	27,96	26	208,02	41,69	41,00	386,60	19,85	18	135,00	4,00
31	27,99	25	207,17	39,55	38,00	403,82	21,15	19	143,03	4,33
33	28,40	26	203,15	40,11	38,00	371,49	21,51	19	140,61	6,33
34	35,32	35	199,04	47,71	47,00	299,01	21,75	20	127,34	8,00
35	33,49	32	215,06	50,56	50,00	387,64	20,97	20	126,37	2,00
36	30,00	29	203,57	44,87	44,00	415,53	21,46	20	144,28	2,00
37	29,90	29	208,59	45,99	45,00	404,85	19,95	18	129,84	2,83
38	31,12	29	201,58	48,70	48,00	454,42	18,53	17	114,88	3,17
39	33,85	33	199,90	52,53	52,00	411,47	18,00	16	115,12	4,17
40	30,94	29	203,70	47,81	47,00	388,28	19,06	17	121,49	4,33
41	31,85	31	203,67	48,59	48,00	415,07	19,69	18	125,62	3,67
43	34,46	33	215,97	52,26	52,00	414,97	17,32	16	112,97	5,50
44	32,08	30	215,71	50,75	50,00	462,72	18,41	16	122,43	5,33
45	32,32	31	195,22	49,26	49,00	425,21	19,39	18	122,71	2,50