

UFRRJ
INSTITUTO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL

DISSERTAÇÃO

TÉCNICAS DE APRENDIZADO DE MÁQUINA NA IDENTIFICAÇÃO
DE PLANTAS DANINHAS NA CULTURA DO MILHO: COMPARAÇÃO
ENTRE *MAXIMUM LIKELIHOOD*, *RANDOM FOREST* E *SUPPORT*
VECTOR MACHINE

THAÍS MACHADO DE SOUZA

2025



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

**TÉCNICAS DE APRENDIZADO DE MÁQUINA NA IDENTIFICAÇÃO
DE PLANTAS DANINHAS NA CULTURA DO MILHO: COMPARAÇÃO
ENTRE *MAXIMUM LIKELIHOOD*, *RANDOM FOREST* E *SUPPORT
VECTOR MACHINE***

THAÍS MACHADO DE SOUZA

Sob a Orientação do Professor
Dr. Murilo Machado de Barros

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental**, no Curso de Pós-Graduação em Engenharia Agrícola e Ambiental, Área de Concentração em Mecanização, Instrumentação e Automação na Agricultura.

Seropédica, RJ

Julho de 2025

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pela autora

S729t Souza, Thaís Machado de, 1996-
Técnicas de aprendizado de máquina na identificação
de plantas daninhas na cultura do milho: comparação
entre maximum likelihood, random forest e support
vector machine / Thaís Machado de Souza. - Seropédica,
2025.
71 f.: il.

Orientador: Murilo Machado de Barros.
Dissertação (Mestrado). -- Universidade Federal Rural
do Rio de Janeiro, Programa de Pós-Graduação em
Engenharia Agrícola e Ambiental, 2025.

1. Aprendizado de máquina. 2. Sensoriamento
remoto. 3. Plantas daninhas. 4. Análise espectral. 5.
Classificação supervisionada . I. Barros, Murilo
Machado de, 1983-, orient. II Universidade Federal
Rural do Rio de Janeiro. Programa de Pós-Graduação em
Engenharia Agrícola e Ambiental III. Título.

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

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

THAÍS MACHADO DE SOUZA

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental**, no Programa de Pós-Graduação em Engenharia Agrícola e Ambiental, área de Concentração em Mecanização, Instrumentação e Automação na Agricultura.

DISSERTAÇÃO APROVADA EM: 28/07/2025

Murilo Machado de Barros, D.Sc, UFRRJ (Orientador/Presidente da Banca)

Anderson Gomide da Costa, D.Sc, UFRRJ

Flávio Castro da Silva, D.Sc, UFF (Externo ao Programa)



ATA Nº 88ª ATA DE DEFESA DE DISSERTAÇÃO DE THAIS MACHADO /2025 - PPGEAAMB
(12.28.01.00.00.00.00.40)
(Nº do Documento: 3691)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 30/07/2025 10:39)

ANDERSON GOMIDE COSTA

PROFESSOR DO MAGISTERIO SUPERIOR

DEPTOENG (12.28.01.00.00.00.00.44)

Matrícula: ###619#5

(Assinado digitalmente em 29/07/2025 15:26)

MURILO MACHADO DE BARROS

PROFESSOR DO MAGISTERIO SUPERIOR

DEPTOENG (12.28.01.00.00.00.00.44)

Matrícula: ###506#5

(Assinado digitalmente em 29/07/2025 14:17)

FLÁVIO CASTRO DA SILVA

ASSINANTE EXTERNO

CPF: ###.###.696-##

(Assinado digitalmente em 29/07/2025 14:20)

THAIS MACHADO DE SOUZA

DISCENTE

Matrícula: 2023#####6

Visualize o documento original em <https://sipac.ufrrj.br/documentos/> informando seu número: 3691, ano: 2025, tipo: ATA, data de emissão: 29/07/2025 e o código de verificação: 3f5e309472

Dedico este trabalho à minha mãe por ser
minha base e fonte de inspiração.

AGRADECIMENTOS

A Deus, que me deu forças para superar cada obstáculo e sabedoria para realizar este trabalho.
À minha mãe Mônica, meu irmão Marcelinho e meu padrasto Marcelo, por serem meu porto seguro, sempre me apoiarem em todos os meus objetivos e me aguentarem em todos os momentos de estresse.

Ao meu namorado, Jefferson, pelo apoio, suporte, paciência e soluções em todo projeto.

Ao meu amigo João Célio, que compartilhou o mestrado comigo, me ajudou em cada etapa, me incentivou e me encorajou.

Ao meu orientador, Prof. Dr. Murilo Machado de Barros, por toda confiança, incentivo e suporte.

Ao Prof. Msc. Ricardo Vilar Neves, pelos ensinamentos, ajuda, incentivo e suporte, essenciais para a concretização deste trabalho.

A todos os professores que contribuíram para a minha formação, meu imenso respeito e admiração.

À Universidade Federal Rural do Rio de Janeiro, por fornecer este curso, permitindo a qualificação profissional.

E a todos aqueles que de alguma forma, contribuíram para êxito deste trabalho, bem como minha formação pessoal e profissional.

“O sucesso não é construído somente durante o dia, você precisa das madrugadas, dos finais de semanas, dos feriados e dos dias santos. Pois a vitória se encontra onde quase ninguém quer ir!” (Evandro Guedes).

RESUMO

MACHADO, Thaís. **Técnicas de Aprendizado de Máquina na Identificação de Plantas Daninhas na Cultura do Milho:** Comparação entre *Maximum Likelihood*, *Random Forest* e *Support Vector Machine*. 2025. 71p. Dissertação (Mestrado em Engenharia Agrícola e Ambiental) - Instituto de Tecnologia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2025.

A cultura do milho (*Zea mays L.*) é uma das mais importantes do agronegócio brasileiro e mundial, sendo fonte essencial de nutrição humana e animal, além de matéria-prima para as indústrias farmacêutica, química, energética e de alimentos. Sua produtividade pode ser severamente comprometida pela presença de plantas daninhas, que competem com a cultura por água, nutrientes e luz. A semelhança visual entre essas espécies, especialmente em estádios precoces de desenvolvimento, dificulta sua identificação. Nesse contexto, o presente trabalho aplicou o uso de técnicas de Sensoriamento Remoto (SR) para discriminação espectral entre milho e daninha (*Cyperus rotundus*), por meio de imagens multiespectrais adquiridas por Aeronaves Remotamente Pilotadas (ARPs). Foram avaliados três classificadores supervisionados – *Maximum Likelihood (ML)*, *Random Forest (RF)* e *Support Vector Machine (SVM)* – estes foram aplicados em diferentes estádios fenológicos e em dois ciclos de cultivo (safra principal e secundária). A acurácia global (AG), assim como as métricas de precisão, *recall* e *F1-score* por classe, foram utilizadas para avaliar o desempenho dos algoritmos na classificação de quatro alvos: *Zea mays L.*, *Cyperus rotundus*, solo e sombra. Foi observada a evolução do desempenho dos classificadores, com o avanço do estágio fenológico. Na análise do primeiro ano (safra secundária) o estágio fenológico V8, foi o mais indicado para a diferenciação entre as plantas, e o classificador de maior desempenho foi o ML, apresentou uma AG de 89%. Para a classe *Zea mays L.* a precisão foi de 0,88, *recall* de 0,81 e *F1-score* de 0,85, e para *Cyperus rotundus* a precisão foi de 0,68, *recall* de 0,89 e *F1-score* de 0,77. No segundo ano (safra principal), a melhor diferenciação foi no estágio fenológico V6, o ML foi novamente o melhor classificador, apresentando uma AG de 88%, com precisão de 1,00, *recall* de 0,78 e *F1-score* de 0,88 para a classe *Zea mays L.*, e precisão de 0,52, *recall* de 1,00 e *F1-score* de 0,68 para a classe de *Cyperus rotundus*. Portanto, nos diferentes anos analisados o classificador ML apresentou melhor desempenho.

Palavras-chave: sensoriamento remoto; classificação supervisionada; estádios vegetativos; análise espectral.

ABSTRACT

MACHADO, Thaís. **Machine Learning Techniques for Weed Identification in Maize Crops:** Comparison between Maximum Likelihood, Random Forest, and Support Vector Machine. 2025. 71p. Dissertation (Master in Agricultural and Environmental Engineering) - Institute of Technology, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2025.

Maize (*Zea mays* L.) is one of the most important crops in Brazilian and global agribusiness, serving as an essential source of food for both humans and animals, as well as a raw material for the pharmaceutical, chemical, energy, and food industries. However, its productivity can be severely affected by the presence of weeds, which compete with the crop for water, nutrients, and sunlight. The visual similarity between species, particularly at early growth stages, hinders their identification. In this context, this study applied Remote Sensing (RS) techniques for the spectral discrimination between maize and the weed *Cyperus rotundus*, using multispectral imagery acquired via Remotely Piloted Aircraft Systems (RPAS). Three supervised classifiers – Maximum Likelihood (ML), Random Forest (RF), and Support Vector Machine (SVM) – were evaluated and applied across different phenological stages and in two crop cycles (main and second crop). Overall Accuracy (OA), along with precision, recall, and F1-score per class, were used to assess the algorithms' performance in classifying four targets: *Zea mays* L., *Cyperus rotundus*, soil, and shadow. An improvement in classification performance was observed as the crop advanced phenologically. In the first year (second crop), the V8 stage proved to be the most suitable for plant differentiation, with ML achieving the highest performance (OA = 89%). For the class *Zea mays* L., precision was 0.88, recall 0.81, and F1-score 0.85; for *Cyperus rotundus*, precision was 0.68, recall 0.89, and F1-score 0.77. In the second year (main crop), the best differentiation occurred at the V6 stage. Once again, ML showed the best performance (OA = 88%), with values of 1.00 for precision, 0.78 for recall, and 0.88 for F1-score in the *Zea mays* L. class, and 0.52 for precision, 1.00 for recall, and 0.68 for F1-score in the *Cyperus rotundus* class. Therefore, in the different years analyzed, the ML classifier showed the best performance.

Keywords: remote sensing; supervised classification; vegetative stages; spectral analysis.

LISTA DE FIGURAS

Figura 01 – Fases Fenológicas da Cultura do Milho.....	19
Figura 02 – Parâmetros estatísticos utilizados pelo classificador <i>Maximum Likelihood</i>	25
Figura 03 – Representação da Árvore de decisão e do <i>Random Forest</i>	26
Figura 04 – Representação do <i>Support Vector Machine</i> para dados linearmente separáveis	27
Figura 05 – Área de estudo do 1º ano	28
Figura 06 – Área de estudo do 2º ano	29
Figura 07 – Coleta de coordenadas com o receptor GNSS HiPer VR.....	30
Figura 08 – DJI Phantom 4 Multispectral	31
Figura 09 – Câmeras do DJI Phantom 4 Multispectral	32
Figura 10 – Fluxograma do processo dos dados obtidos no aerolevanteamento	34
Figura 11 – Classificação <i>Maximum Likelihood</i> , do primeiro ano, estágio fenológico V4 ..	35
Figura 12 – Classificação <i>Random Forest</i> , do primeiro ano, estágio fenológico V4	36
Figura 13 – Classificação <i>Support Vector Machine</i> , do primeiro ano, estágio fenológico V4	36
Figura 14 – Classificação <i>Maximum Likelihood</i> , do primeiro ano, estágio fenológico V6 ..	41
Figura 15 – Classificação <i>Random Forest</i> , do primeiro ano, estágio fenológico V6	41
Figura 16 – Classificação <i>Support Vector Machine</i> , do primeiro ano, estágio fenológico V6	42
Figura 17 – Classificação <i>Maximum Likelihood</i> , do primeiro ano, estágio fenológico V8 ..	46
Figura 18 – Classificação <i>Random Forest</i> , do primeiro ano, estágio fenológico V8	46
Figura 19 – Classificação <i>Support Vector Machine</i> , do primeiro ano, estágio fenológico V8	47
Figura 20 – Classificação <i>Maximum Likelihood</i> , do segundo ano, estágio fenológico V2 ..	51
Figura 21 – Classificação <i>Random Forest</i> , do segundo ano, estágio fenológico V2.....	51
Figura 22 – Classificação <i>Support Vector Machine</i> , do segundo ano, estágio fenológico V2	52
Figura 23 – Classificação <i>Maximum Likelihood</i> , do segundo ano, estágio fenológico V6 ..	56
Figura 24 – Classificação <i>Random Forest</i> , do segundo ano, estágio fenológico V6.....	57
Figura 25 – Classificação <i>Support Vector Machine</i> , do segundo ano, estágio fenológico V6	57

LISTA DE TABELAS

Tabela 01 – Estádio fenológico e sua caracterização	19
Tabela 02 – Matriz de confusão: classificação <i>Maximum Likelihood</i> do primeiro ano, estágio fenológico V4.....	37
Tabela 03 – Matriz de confusão: classificação <i>Random Forest</i> do primeiro ano, estágio fenológico V4.....	38
Tabela 04 – Matriz de confusão: classificação <i>Support Vector Machine</i> do primeiro ano, estágio fenológico V4	39
Tabela 05 – Matriz de confusão: classificação <i>Maximum Likelihood</i> do primeiro ano, estágio fenológico V6.....	42
Tabela 06 – Matriz de confusão: classificação <i>Random Forest</i> do primeiro ano, estágio fenológico V6.....	43
Tabela 07 – Matriz de confusão: classificação <i>Support Vector Machine</i> do primeiro ano, estágio fenológico V6	44
Tabela 08 – Matriz de confusão: classificação <i>Maximum Likelihood</i> do primeiro ano, estágio fenológico V8.....	47
Tabela 09 – Matriz de confusão: classificação <i>Random Forest</i> do primeiro ano, estágio fenológico V8.....	48
Tabela 10 – Matriz de confusão: classificação <i>Support Vector Machine</i> do primeiro ano, estágio fenológico V8	49
Tabela 11 – Matriz de confusão: classificação <i>Maximum Likelihood</i> do segundo ano, estágio fenológico V2.....	52
Tabela 12 – Matriz de confusão: classificação <i>Random Forest</i> do segundo ano, estágio fenológico V2.....	53
Tabela 13 – Matriz de confusão: classificação <i>Support Vector Machine</i> do segundo ano, estágio fenológico V2	54
Tabela 14 – Matriz de confusão: classificação <i>Maximum Likelihood</i> do segundo ano, estágio fenológico V6.....	58
Tabela 15 – Matriz de confusão: classificação <i>Random Forest</i> do segundo ano, estágio fenológico V6.....	59
Tabela 16 – Matriz de confusão: classificação <i>Support Vector Machine</i> do segundo ano, estágio fenológico V6	60

LISTA DE ABREVIATURAS E SIGLAS

AG – Acurácia Global

ANAC – Agência Nacional de Aviação Civil

ARP – Aeronave Remotamente Pilotada

CTUR – Colégio Técnico da Universidade Federal Rural do Rio de Janeiro

DAS – Dias Após a Semeadura

DJI – *Dà-Jiâng Innovations Science and Technology*

GNSS – *Global Navigation Satellite System*

GSD – *Ground Sample Distance*

IAF – Índice de Área Foliar

ML – *Maximum Likelihood*

ONRJ – Observatório Nacional do Rio de Janeiro

PGEAAMB – Pós-Graduação em Engenharia Agrícola e Ambiental

RBMC – Rede Brasileira de Monitoramento Contínuo

RF – *Random Forest*

RJNI – Rio de Janeiro-Niterói

SIRGAS – Sistema de Referência Geocêntrico para as Américas

SR – Sensoriamento Remoto

SVM – *Support Vector Machine*

UFRRJ – Universidade Federal Rural do Rio de Janeiro

WGS – *World Geodetic System*

SUMÁRIO

1 INTRODUÇÃO	15
2 OBJETIVOS.....	17
2.1 Objetivo geral	17
2.2 Objetivos específicos	17
3 REVISÃO DE LITERATURA.....	18
3.1 Cultura do Milho.....	18
3.2 Plantas Daninhas.....	21
3.3 Sensoriamento Remoto	22
3.4 Aeronave Remotamente Pilotada	24
3.5 Aprendizado de Máquina Supervisionado.....	25
4 MATERIAL E MÉTODOS.....	28
4.1 Área de Estudo	28
4.1.1 Preparação da Área.....	29
4.2 Aerolevanteamento	30
4.2.1 Processamento dos dados obtidos no aerolevanteamento	32
5 RESULTADOS E DISCUSSÃO.....	35
5.1 Primeiro Ano	35
5.1.1 Estádio V4	35
5.1.2 Estádio V6	40
5.1.3 Estádio V8	45
5.2 Segundo Ano.....	51
5.2.1 Estádio V2	51
5.2.2 Estádio V6	56
5.3 Considerações sobre as safras	61
6 CONCLUSÃO	63
REFERÊNCIAS	64

1 INTRODUÇÃO

O milho é uma *commodity* essencial para a segurança alimentar global (SHAH et al., 2025). Segundo a *Food and Agriculture Organization of the United Nations* (2024), este cereal tem apresentado o maior crescimento de produção mundial desde 2010, com aumento de 46%, superando os demais grãos em ritmo de expansão.

No Brasil, a produção das três safras do milho 2024/25, está estimada em 128,3 milhões de toneladas, sendo 24,8 milhões de toneladas na primeira safra, 101 milhões de toneladas na segunda safra e 2,4 milhões de toneladas na terceira safra (CONAB, 2025). O Brasil ocupa o primeiro lugar como maior exportador de milho do mundo e o terceiro maior produtor deste grão. No ano de 2024, os maiores importadores do milho foram: Egito, Vietnã, Irã, Coreia do Sul e Japão (USDA, 2025).

Segundo Duarte, Mattoso e Garcia (2021), do total do volume de milho produzido no país cerca de 60% a 80% é destinado à nutrição de suínos, bovinos e aves. Além disso, o milho também está sendo aplicado na produção de etanol, na qual de acordo com a projeção da União Nacional do Etanol do Milho (2025), na safra 2025/26 o Brasil produzirá 9,9 bilhões de litros.

Sabe-se que para um bom rendimento da colheita é necessária uma boa gestão da lavoura, o que implica diretamente no controle de pragas, doenças e plantas daninhas, por exemplo. As plantas daninhas são as maiores responsáveis por afetar a economia agrícola, tendo em vista que além de reduzir a produtividade devido aos danos fisiológicos da cultura, geram gastos para seu controle, resultando na elevação dos custos de produção (MARQUES et al., 2024).

O uso de produtos químicos para o controle de plantas daninhas, deixou de ser uma solução à longo prazo, devido à diversidade de plantas daninhas e à resistência aos herbicidas. Mediante a isto, tornou-se essencial maximizar a eficácia no controle de plantas daninhas, utilizando-se de herbicidas com modos de ação mais específicos, associados a práticas agrícolas mais sustentáveis, juntamente com implementação de tecnologias de aplicação mais precisa (BERRÚZ, 2024).

O manejo específico de plantas daninhas, do termo em inglês *Site-Specific Weed Management*, tem sido uma estratégia adotada baseada na pulverização localizada, reduzindo os impactos ambientais. Esta técnica, tem sido aplicada através do uso de ferramentas do Sensoriamento Remoto como as Aeronaves Remotamente Pilotadas (ARPs) para a detecção e mapeamento de plantas daninhas em diferentes campos agrícolas, juntamente com técnicas de aprendizado de máquinas para a classificação de imagens (BRETAS et al., 2024).

As ARPs apresentam sensores embarcados que permitem a obtenção de imagens de resolução otimizada, onde torna-se possível por meio do uso de *softwares*, realizar a classificação das imagens e identificar as classes da superfície do solo. Dentre estas classes as ARPs têm se mostrado ferramentas eficazes na detecção de plantas daninhas, por meio da aquisição de imagens, tornando possível a discriminação de áreas infestadas e adoção de práticas de manejo mais precisas. Neste contexto, Tetila et al. (2025) utilizaram imagens obtidas por ARP e classificadores na detecção e reconhecimento de plantas daninhas em lavouras de milho, destacando o potencial dessa tecnologia no monitoramento agrícola.

As técnicas de aprendizado de máquinas têm sido aplicadas para extrair as informações de interesse das imagens, considerando o grande volume de dados gerados nesse tipo de avaliação e o avanço das capacidades computacionais que possibilitam seu processamento eficiente. Classificadores como *Support Vector Machine* (SVM), *Random Forest* (RF) e *Maximum Likelihood* (ML) apresentam ampla aplicação em sensoriamento remoto e elevado desempenho em contextos agrícolas, sendo estes consolidados na detecção de plantas daninhas.

O SVM apresenta alta capacidade de generalização, mesmo com conjuntos de treino reduzidos, sendo eficaz na separação de classes espectralmente semelhantes (GU; CONGALTON, 2025). O RF é reconhecido pelo seu desempenho frente à variabilidade espectral (LIU et al., 2025). Já o ML, apresenta alto desempenho para áreas agrícolas em que há relativa homogeneidade espectral, e elevada acurácia para classificação baseada em pixel (KIM et al., 2023; PHIRI et al., 2020).

Wolfer (2020) utilizou classificadores como *Random Forest* e *Support Vector Machine* na classificação supervisionada de usos e cobertura da terra, tendo estes uma acurácia, respectivamente, de 99,73% e 99,37%. Assim como, Sefercik et al. (2021) utilizou o classificador *Maximum Likelihood* em imagens multiespectrais para classificar diferentes coberturas do solo alcançando uma acurácia de 93,56 %.

Diante disto, este estudo buscou utilizar o ML, RF e o SVM para realizar a classificação baseada em pixels, de áreas com cultura do milho e presença de daninhas. Também buscou-se comparar os classificadores e definir o estágio fenológico mais adequado para distinção entre as espécies, considerando o período de convivência tolerável entre a cultura do milho e a daninha, a fim de não comprometer o rendimento da cultura.

2 OBJETIVOS

2.1 Objetivo geral

Aplicar classificadores supervisionados para detectar plantas daninhas em diferentes estádios da cultura do milho, a partir do uso de imagens multiespectrais obtidas por Aeronaves Remotamente Pilotadas (ARPs).

2.2 Objetivos específicos

- a) Avaliação de detecção de plantas daninhas em diferentes instantes ao longo do crescimento da cultura utilizando imagens multiespectrais obtidas por ARP;
- b) Determinação do melhor classificador para distinção da cultura e da daninha;
- c) Determinação do estágio fenológico mais adequado para a distinção entre as plantas.

3 REVISÃO DE LITERATURA

3.1 Cultura do Milho

O milho pertence à família *Poaceae* e sua espécie é a *Zea mays L.* (MAGALHAES; SOUZA, 2015). É uma espécie de elevada adaptação a diferentes condições ambientais, com plantas de metabolismo fotossintético C4. A cultura expressa seu máximo potencial produtivo quando exposta a uma temperatura de 20 a 30°C, radiação solar elevada e disponibilidade hídrica adequada (SIATWIINDA, 2021).

Esta cultura está entre as mais antigas do mundo, sendo considerada de grande importância comercial com origem nas Américas. O milho é um alimento básico com produção total superior a produção de trigo e de arroz (REHMAN et al., 2021). A sua relevância econômica é caracterizada pelas diversas formas de utilização seja na alimentação humana, alimentação animal, indústrias de alta tecnologia, fornecimento de bioetanol e biomassa para produção de energia (DUARTE; MATTOSO; GARCIA, 2021; MOSSANDE, 2022).

O milho, no Brasil, é cultivado por pequenos, médios e grandes produtores, e sua produção e consumo seguem progredindo, sendo um dos principais segmentos do agronegócio brasileiro, responsável por ser a terceira cultura de maior geração de renda no país (CARMO, 2023). Além disso, é a terceira cultura de cereais mais importante do mundo (ALI et al., 2020; ASIF et al., 2020).

Segundo Magalhães e Durães (2006), o sistema de identificação dos estádios de desenvolvimento da planta é dividido em vegetativo e reprodutivo. Os estádios vegetativos são caracterizados por VE (primeiro estágio vegetativo), V1 até V(n), onde (n) consiste na última folha emitida antes do pendoamento e VT (último estágio vegetativo). Enquanto os estádios reprodutivos variam de R1 (primeiro estágio reprodutivo) até R6 (último estágio reprodutivo), como ilustrado na Figura 01.

Figura 01 – Fases Fenológicas da Cultura do Milho.



Fonte: Adaptado Mosaic Fertilizantes (2021).

Cada estágio de desenvolvimento é marcado por características analisadas na cultura, como presença ou ausência de algum atributo. Venancio et al. (2020) especificam em seu experimento os estádios fenológicos, com suas respectivas descrições, e o número médio de dias após a semeadura (DAS) das principais fases de crescimento do milho, como demonstrado na Tabela 01.

Tabela 01 – Estádio fenológico e sua caracterização.

Estádio Fenológico	Descrição do estágio	DAS
Fase Vegetativa		
VE	Emergência	05
V2	Duas folhas emergiram totalmente	12
V4	Quatro folhas emergiram totalmente	19
V6	Seis folhas emergiram totalmente	26
V8	Oito folhas emergiram totalmente	33
V10	Dez folhas emergiram totalmente	41
V12	Doze folhas emergiram totalmente	49
V14	Quatorze folhas emergiram totalmente	60
VT	Pendoamento	67
Fase Reprodutiva		
R1	Floração	74
R2	Grão Bolha	94
R3	Grão Leiteiro	100
R4	Grão Pastoso	110
R5	Formação de Dente	120
R6	Maturidade Fisiológica	130

Fonte: Adaptado Venancio et al. (2020).

O conhecimento sobre os estádios fenológicos é essencial, tendo em vista que diversos estudos mostram com base nas fases fenológicas qual o momento mais adequado para o controle

de daninhas, visando evitar o comprometimento da produtividade da cultura. Kozlowski et al. (2009) apontam que do estágio V2 a V7, é o período mais crítico à exposição de plantas daninhas, e que requer intervenção e controle, ainda assim, afirmam que após a primeira medida de controle pode surgir um novo fluxo de plantas daninhas capaz de afetar a produtividade, sendo normalmente determinada nos estádios V4, V6 e V7.

Segundo Vargas et al. (2006), os maiores prejuízos ocorrem na competição entre 20 e 60 dias, sendo a competição anterior aos 20 dias após a emergência (planta de milho com menos de três folhas) e 60 dias após a emergência (planta de milho com 12 folhas ou mais) “aceitável” por não comprometer o rendimento do grão. Porém, esses períodos variam de acordo com a agressividade da planta daninha, densidade de semeadura, estágio de desenvolvimento da cultura e das daninhas e clima da região. Portanto, de acordo com Kozlowski et al. (2002) o período total de prevenção de daninhas para evitar comprometimento da produtividade deve ocorrer desde a emergência do milho até o estágio V7.

A cultura do milho na safra principal é beneficiada pela temperatura moderada e chuvas bem distribuídas durante sua fase de crescimento, enquanto na safra secundária o rendimento é reduzido por menos precipitações em fases críticas da cultura (PILECCO, 2023). De acordo com Colussi et al. (2024) a safra secundária (safrinha) do milho deve ser plantada no período de janeiro ao início de março, para evitar maturação da cultura na estação seca, já que a produtividade pode ser reduzida, sendo este período em meados de abril. Semeaduras tardias podem apresentar reduções entre 50 e 89% na produtividade devido temperaturas elevadas e eventos de seca (ANDREA, et al. 2019).

Ge et al. (2025) demonstraram que a predição da produtividade do milho pode ser aprimorada quando se consideram imagens obtidas por ARP analisadas em diferentes estádios fenológicos da cultura, integrando índices de vegetação a classificadores de aprendizado de máquina para captar variações no desenvolvimento das plantas ao longo do ciclo. De forma complementar, Askale et al. (2025) aplicaram algoritmos de aprendizado profundo para a detecção e classificação de doenças foliares em distintos estádios de crescimento, possibilitando o diagnóstico precoce e contribuindo para a redução de perdas de rendimento.

Já Villiers et al. (2023) investigaram a precisão do mapeamento de infestações de plantas daninhas na cultura do milho a partir de dados multitemporais obtidos por ARPs, aplicando algoritmos de aprendizado de máquina (SVM e RF). O estudo buscou identificar quais estádios fenológicos do milho foram mais adequados na detecção das plantas daninhas, sem considerar, entretanto, o período de convivência entre as espécies. Para avaliar o desempenho dos classificadores em cada estágio de crescimento, foram utilizados indicadores como acurácia

global, precisão, *recall*, *F1-score* e validação cruzada.

3.2 Plantas Daninhas

São plantas indesejadas que crescem espontaneamente e podem danificar e reduzir o rendimento das colheitas, causando elevados prejuízos com o tempo, caso nenhuma ação seja tomada para controlar a taxa de crescimento (CHE'YA; DUNWOODY; GUPTA, 2021).

O principal fator para a propagação das plantas daninhas está associado a grande resistência às adversidades externas. A presença de plantas daninhas em uma lavoura gera perda na produção agrícola, infestação de áreas não agrícolas, infestação de canais de irrigação e danos a implementos agrícolas, surgimento de alergia e intoxicação do homem e de animais (ROSSETTO; SANTIAGO, 2022).

Diante disto, são consideradas um grande problema, já que interferem de maneira significativa no desenvolvimento da lavoura e competem por recursos naturais (água, luz e nutrientes do solo), podendo ocasionar uma queda no rendimento das culturas de 45 a 95% (CHE'YA; DUNWOODY; GUPTA, 2021). A competição entre as plantas ocorre quando os recursos são limitados, e este problema é agravado quanto maior a semelhança morfológica entre a planta daninha e a cultura, dificultado a determinação do melhor tipo de controle (MANGANIELI, 2024).

Segundo Concenço et al. (2024) e Mendonça et al. (2023), é importante a realização de levantamentos sobre a ocorrência de plantas daninhas nas culturas, através de um acompanhamento de médio e longo prazo analisando as alterações da flora infestante. Assim, é possível averiguar se os métodos de manejo estão eficazes na supressão de daninhas, e determinar qual a melhor técnica de controle (químico, cultural ou mecânico).

Frequentemente, devido à preocupação com ações mais precisas e eficientes que geram menores danos ao meio ambiente, tem-se realizado o mapeamento de plantas daninhas com base na diferença das respostas espectrais ou em índices de vegetação que distinguem as plantas das culturas das plantas daninhas (QUINTANILLA et al., 2018). Isto, permite um gerenciamento localizado, levando em conta a variabilidade das diferentes classes na área de plantio.

Nascimento et al. (2024) realizou o mapeamento de plantas daninhas após a colheita do milho em sistema de plantio direto e determinou que as principais espécies presentes eram capim colômbio (*Panicum Maximum*), botão de ouro (*Unxia kubitzkii*), trapoeraba (*Commelina benghalensis*), poaia (*Richardia brasiliensis*), picão preto (*Bidens pilosa*), tiririca (*Cyperus rotundus*) e beldroega (*Postulaca oleraceae*).

Silva et al. (2015) avaliou em seu trabalho a interferência da *Cyperus rotundus* sobre o crescimento e rendimento de grãos da cultura do milho, analisando a cultura em diferentes densidades desta planta daninha, concluiu que o controle da tiririca, mesmo em baixas densidades, é necessário, tendo em vista que a presença desta planta causa efeito negativo no crescimento do milho com consequências diretas na produtividade de grãos da cultura. A redução na produtividade foi próxima a 10% na presença de 10 pl/m², o que corresponde a aproximadamente 16 sacas de 60 quilos de milho.

As condições de temperatura e umidade distintas entre as safras modificam a composição da comunidade infestante no milho. Entretanto, a *Cyperus rotundus* é uma das espécies que emerge tanto no período de safra principal como mostra Jakelaitis (2003), quanto no período de safra secundária como apontado por Silva, Guimarães e Pinotti (2018). De acordo com Peerzada (2017) estruturas perenes, como tubérculos e rizomas, permitem que *Cyperus rotundus* se regenere, além da diversidade genética, sua capacidade de tolerar condições climáticas adversas, a alta taxa de reprodução, a facilidade de dispersão, a forte capacidade competitiva e o potencial alelopático. Sendo capaz de competir com culturas como o milho o ano inteiro.

Segundo Sarvestani et al. (2025) a identificação precoce de plantas daninhas, principalmente nos estádios iniciais da cultura, possibilita a obtenção de informações de distribuição espacial e análise da densidade, permitindo a adoção adequada de medidas de controle, como aplicação de herbicidas, de maneira localizada e no período mais eficiente de acordo com a espécie, de forma a reduzir custos e resíduos ambientais.

3.3 Sensoriamento Remoto

O sensoriamento remoto é definido como a área do conhecimento a qual por meio de um sensor são obtidas informações dispostas na superfície terrestre através da interação da radiação eletromagnética com alvos de interesse sem a necessidade do contato direto com as culturas agrícolas (CRUSIOL et al., 2024).

O SR pode ser definido pelo nível de aquisição dos dados em: orbital (satélites), sub-orbital ou aéreo (aeronaves) e terrestre (espectrorradiômetros e máquinas fotográficas), no qual captam não somente a energia refletida por meio da interação da radiação com os alvos, mas também a variação dos comprimentos de onda e das faixas espectrais (MOLIN; AMARAL; COLAÇO, 2015; COSTA, 2019).

A análise da interação da luz com a matéria, pode ser usada para caracterizar a natureza e a composição de diversos materiais. Através da medição da luz incidente refletida de uma

superfície ou material (MCGUIRK; CAIRNS, 2024). Quando a luz incide em uma superfície, parte dela é absorvida, parte é transmitida através da superfície e parte é refletida, sendo a quantidade de luz refletida dependente das propriedades do material e ângulo de incidência da luz (CHEN, 2024).

As propriedades ópticas da folha dependem da sua estrutura, da composição bioquímica, da distribuição dos componentes bioquímicos da folha e do índice de refração complexo desses componentes (THENKABAIL et al., 2012). A clorofila, por exemplo, absorve grande parte da energia nas faixas de comprimento de onda de 0,45 e 0,67 μm . Em 0,7 μm , na vegetação saudável, há um aumento na reflectância. De 0,7 a 1,3 μm , a folha da planta reflete de 40 a 50% da energia incidente sobre ela, sendo a reflectância resultado principalmente da estrutura interna das folhas. Portanto, as medições de reflectância nessa faixa frequentemente, permitem discriminar as espécies, ainda que pareçam iguais em comprimentos de onda na região do visível (JOSEPH; DASH; RASHEED, 2016).

Já o solo, segundo Rossel et al. (2006) apresenta suas propriedades nas diferentes regiões do espectro, sendo as análises feitas mediante ao que deseja ser estudado, por exemplo, predição de CO e pH do solo são evidentes na faixa do visível (0,4 – 0,7 μm), já no infravermelho próximo (0,7 – 2,5 μm) tem-se a informação sobre os picos de absorção associados as ligações O-H, e na região do infravermelho médio (2,5 – 25 μm) obtém-se análises de compostos orgânicos.

Percebe-se que análises espectrais permitem formular estratégias na agricultura para a eficiência da produção. Kipkulei (2024) e Liao et al. (2019) usaram dados obtidos por sensoriamento remoto para avaliar a fenologia, biomassa e produtividade do milho. Já Mkhize et al. (2024), utilizaram imagens de satélites, para determinar daninhas na cultura de milho por meio de respostas espectrais. Zanin et al. (2022), apontou uma redução no custo com herbicida em 56,16% na cultura do milho e soja, por meio da pulverização localizada de acordo com a identificação do alvo por sua resposta espectral.

As principais questões, nas quais o sensoriamento remoto tem que lidar durante o mapeamento de plantas daninhas, são: a mistura espectral por causa dos diferentes estádios fenológicos das culturas e das plantas daninhas; os algoritmos eficientes de mapeamento de plantas daninhas e o efeito da resolução da imagem no mapeamento (QUINTANILLA et al., 2018).

O uso de tecnologias de SR, como satélites e ARPs, permite o acesso a informações espaciais detalhadas e de alta resolução facilitando o mapeamento preciso, por meio da captura de imagens, que permitem o monitoramento do rendimento das culturas, detecção de plantas

daninhas, mapeamento de doenças na cultura e a criação de limites de campo definidos com precisão (MONTEIRO; SANTOS; GONÇALVES, 2021; PHANG et al., 2023; SOUSSI et al., 2024).

3.4 Aeronave Remotamente Pilotada

A Aeronave Remotamente Pilotada é a classe de aeronave não tripulada usada para outros fins que não a recreação, com alto grau de automatismo, para uso comercial, corporativo ou experimental (ANAC, 2017).

No Brasil, o marco inicial dessa inovação foi em 1982, no desenvolvimento de um projeto de um Veículo Aéreo Não-Tripulado à jato pela parceria entre a Companhia Brasileira de Tratores e o Centro Técnico Aeroespacial. O projeto não avançou, mas houve interesse pela tecnologia por parte de outros órgãos, como marinha, exército e aeronáutica, na qual a ARP serviu como alvo em práticas de combates aéreos e treinamento de tiros nas unidades antiaéreas (CAMARGO, 2018).

A partir de 1990, houve uma percepção sobre as aplicações na esfera civil, tais como: Infraestrutura, Mídia e Entretenimento, Telecomunicações, Agricultura, Segurança, Busca e Salvamento, Mineração, dentre outros (DECEA, 2020).

As ARPs apresentam diversas aplicações na agricultura, tais como: estimativa de produtividade nas culturas e cultivos, identificação de focos de pragas, doenças, plantas daninhas, mapeamento de adubação e irrigação, bem como mapeamento para ações corretivas, e pulverização. Diante disto, são fundamentais para monitoramento preciso das lavouras, tornando o cultivo eficiente, tecnológico e sustentável (BUENO et al., 2023; CAVALCANTE et al., 2022).

O acoplamento de câmeras nas ARPs permite coletar dados de alta resolução em nível de campo em tempo real. Uma das principais funções da ARP é adquirir imagens visíveis, espectrais, infravermelhas ou térmicas com elevada resolução em baixa altitude visando o controle de áreas agrícolas extensas e previsão de possíveis problemas (GAŠPAROVIĆ et al., 2020; PANDAY et al., 2020).

Du et al. (2022) utilizou imagens de ARP para estimar o índice de área foliar ao longo do ciclo do milho, comparando modelos estatísticos e de *machine learning*, destacando a importância do uso da aeronave na realização da análise de forma não destrutiva, e na otimização do tempo de resposta.

No estudo de daninhas na cultura do milho, Fedoniuk (2025) empregou ARP para monitorar e prever a propagação de plantas daninhas, estimando o nível de infestação em

campos de milho, por meio de dados multiespectrais. Enquanto Zhao et al. (2025), utilizou ARP na obtenção de imagens multiespectrais, para que estas fossem classificadas através de aprendizado de máquina a fim de analisar o acamamento do milho.


3.5 Aprendizado de Máquina Supervisionado

É um método de inteligência artificial capaz de treinar modelos para fazer classificações com base em dados de entrada rotulados, criando padrões de aprendizado, por meio de técnicas de otimização (BURKART; HUBER, 2021; NIE et al., 2022). A acurácia da classificação supervisionada depende fortemente da qualidade e representatividade dos dados de treinamento (ABBURU; GOLLA, 2015).

Diversos algoritmos são utilizados para estas classificações, dentre eles *Maximum Likelihood*, *Random Forest* e *Support Vector Machine*. O desempenho dos diferentes algoritmos de aprendizado de máquinas supervisionado varia dependendo da tarefa específica de visão computacional (SEN; HAJRA; GHOSH, 2020).

De acordo com Rawat, Kumar e Garg (2024) o *Maximum Likelihood* (ML) é amplamente utilizado em sensoriamento remoto e processamento de imagens para classificar valores de pixels em diferentes categorias de cobertura do solo, baseando-se em parâmetros estatísticos, como média, variância e covariância, Figura 02.

Figura 02 – Parâmetros estatísticos utilizados pelo classificador *Maximum Likelihood*.



Fonte: Elaboração própria.


Esses parâmetros são estimados usando o critério de máxima verossimilhança, ou seja, calcula-se a probabilidade de cada valor de pixel pertencer a cada classe com base no modelo de distribuição normal multivariada. Com isso cada pixel é atribuído a classe a qual tem maior probabilidade de pertencer, dados seus valores espectrais observados, sendo o ML estável diante de ruídos e valores discrepantes nos dados, devido à sua estrutura probabilística (RAWAT;

KUMAR; GARG, 2024; STIGLER, 2007).

Mattivi et al. (2021), utilizaram o classificador *Maximum Likelihood*, juntamente com rede neural e Análise de Imagens Baseada em Objetos, para fazer um comparativo entre os resultados das imagens aéreas capturadas por ARP no mapeamento de plantas daninhas dominantes no campo de milho, gerando ao final mapas de aplicação localizada de herbicidas.

O *Random Forest*, consiste na construção de uma multiplicidade de árvores de decisão, na qual uma porcentagem dos dados do conjunto estudado é utilizada na construção do modelo das árvores e outra em seu treinamento. Este conjunto de dados é formado por observações e atributos que são selecionados aleatoriamente e que posteriormente são usados na divisão de nós, tendo em vista que uma árvore de decisão é composta por nó raiz, nó de decisão e nó terminal, sendo o nó terminal o resultado específico de uma determinada árvore (SALMAN; KALAKECH; STEITI, 2024). Na Figura 03, é possível observar a esquematização da Árvore de decisão e do *Random Forest*.

Figura 03 – Representação da Árvore de decisão e do *Random Forest*.



Fonte: Elaboração própria.


O *Random Forest* pode ser utilizado para classificação e regressão. Na classificação o resultado é obtido por meio da classe majoritária entre as árvores, ou seja, com base na moda das classes, portanto, cada árvore criada fornece uma classificação temporária para cada pixel da imagem, sendo a classe atribuída a um determinado pixel resultado do cálculo da moda. Na regressão, o resultado consiste na previsão média das árvores individuais (JÚNIOR; JÚNIOR; PACHECO, 2021; NICOLETTI et al., 2023). Yang, Prasher e Goel (2004), analisaram os

resultados do classificador *Random Forest* na diferenciação de cenários com cultura de milho e soja, com e sem daninhas utilizando imagens multiespectrais.

Já o *Support Vector Machine* desenvolvido por Vapnik no final da década de 1970, tornou-se um dos métodos baseados em kernel mais utilizados no aprendizado de máquina, principalmente em tarefas de classificação de imagens, sendo um classificador linear binário, não probabilístico que busca identificar um hiperplano ótimo para separar os dados em diferentes classes (ZHU; BLUMBERG, 2002; MOUNTRAKIS; IM; OGOLE, 2011).

Esse hiperplano é definido de modo a maximizar a margem de separação entre os grupos, utilizando como referência os vetores de suporte, que são as amostras mais próximas da fronteira de decisão e, portanto, mais difíceis de classificar, como ilustrado na Figura 04.

Figura 04 – Representação do *Support Vector Machine* para dados linearmente separáveis.



Fonte: Elaboração própria.

O processo de escolha do hiperplano ideal ocorre de forma iterativa, sendo descrito como o processo de aprendizagem no qual a margem máxima é determinada para reduzir ao mínimo os erros de classificação durante o treinamento. Trata-se de uma abordagem supervisionada e não paramétrica, ou seja, não depende de pressupostos sobre a distribuição dos dados, diferentemente de métodos como o *Maximum Likelihood* (KAVZOGLU; TSO; MATHER, 2024). Veramendi e Cruvinel (2024), utilizaram o classificador *Support Vector Machine*, na determinação de contagem de plantas do milho em imagens multiespectrais adquiridas por ARP, visando analisar a produtividade.

A classificação de imagens tornou-se o meio mais eficaz para determinação de classes ocupantes, sendo o principal objetivo, independente da variedade de usos das imagens de sensoriamento remoto, a extração de informações da paisagem das imagens (JÚNIOR et al., 2024).

4 MATERIAL E MÉTODOS

4.1 Área de Estudo

O estudo foi realizado, em diferentes períodos, em duas áreas da Universidade Federal Rural do Rio de Janeiro, localizada no município de Seropédica, Rio de Janeiro, Brasil. A análise no primeiro ano, cuja área, Figura 05, apresenta como coordenadas geográficas: 22°46'37" S; 43°41'36" W, Datum WGS 84, Zona 23 S, compreendeu os meses de abril e maio de 2024 (safra secundária).

Figura 05 – Área de estudo do 1º ano.



Fonte: Elaboração própria.

Já a análise do segundo ano, cuja área, Figura 06, apresenta como coordenadas geográficas: 22°47'33" S; 43°41'20" W, Datum WGS 84, Zona 23 S, abrangeu os meses de janeiro e fevereiro de 2025 (safra principal).

Figura 06 – Área de estudo do 2º ano.



Fonte: Elaboração própria.

A semeadura da cultura do milho, no período da safra secundária e da principal, ocorreu respectivamente em 05 de abril de 2024 e 23 de dezembro 2024. Ambas áreas de estudo foram delimitadas em 1 ha.

O clima predominante da região, segundo a classificação de Köppen, é do tipo Aw (ALVARES et al., 2014), definido como tropical úmido de savana com verões chuvosos e invernos secos. A precipitação total é de 1.274 mm e a temperatura média anual é de 23,7° C (SILVA; DEREZYNSKI, 2014).

4.1.1 Preparação da Área

Nas áreas de estudo, adotou-se o preparo convencional do solo, com a realização de aração seguida de gradagem, para a desagregação dos torrões e nivelamento da superfície, respectivamente. Sequencialmente, realizou-se a aplicação de calcário, para correção da acidez do solo. Por fim, foi realizada a semeadura do milho.

No primeiro ano foi semeada a cultivar híbrida BM 3063 PRO 2 e no segundo a BM 790 PRO 3, da empresa Biomatrix, as duas utilizadas para silagem de planta inteira. O uso de diferentes híbridos do primeiro ano para o segundo ano, consistiu em avaliar o desempenho do classificador em diferentes cenários de cultivares. Além disto, no primeiro ano, por se tratar do período da safra secundária a população (plantas/ha) foi de 60 mil, e no segundo ano, na safra

principal, 70 mil, sendo em ambos casos mantidos o espaçamento entre linhas de 0,80 m.

Em cada área, foram obtidas as coordenadas de 30 pontos de controle, para posteriormente realizar o georreferenciamento das imagens, conforme a recomendação da *American Society for Photogrammetry and Remote Sensing* (2023) para áreas de até 1000 km². Para isto foi utilizado um par de receptores GNSS, Hiper VR, sendo um operado como base, Figura 07, e outro como rover, com aplicação do método RTK.

Figura 07 – Coleta de coordenadas com o receptor GNSS HiPer VR.



Fonte: Elaboração própria.

O processamento dos dados da base foi feito no Laboratório de Geodésia e Cartografia, na UFRRJ. Os dados descarregados no formato “rinex”, foram importados pelo *software Topcontolls*, onde foi feita a correção das coordenadas utilizando a RBMC – RioON e RJNI – cuja média da incerteza do levantamento em Norte (N) e Este (E) foi de 4 mm.

4.2 Aerolevantamento

O período estimado como limite de convivência entre plantas daninhas e milho, visando não ter perdas significativas na produção é o período do estágio fenológico V2 ao V8, caracterizado como o estágio de maior importância relativa para plantas daninhas como *Cyperus rotundus*, chamada de tiririca (OLIVEIRA et al., 2024; PIAZENTINE, 2021; VARGAS et al., 2006). Em todos os estádios de coleta foram realizadas análises em campo para validar os locais de ocorrência de daninhas, juntamente com as regiões identificadas nas imagens. A *Cyperus rotundus*, foi a única espécie constatada em ambas as áreas desse estudo.

No primeiro ano, no estágio V2, verificou-se nas imagens, a não ocorrência da daninha, e em virtude da insuficiência de dados amostrais para a *Cyperus rotundus* este estágio fenológico não foi utilizado no estudo. Mediante a isto, neste ano, os voos utilizados na análise foram realizados em três dias, correspondendo aos estádios fenológicos V4, V6 e V8, referente

respectivamente à 19, 24 e 31 dias após a semeadura (DAS), nas datas: 24 de abril, 29 de abril e 06 de maio, do ano de 2024.

No segundo ano, as condições meteorológicas, especialmente em relação ao vento e à precipitação, inviabilizaram o levantamento aéreo programado para o estádio V4. E no estádio V8, o alto índice de cobertura vegetal promovido pelo dossel do milho reduziu significativamente a penetração luminosa no estrato inferior, inibindo a germinação e o crescimento de espécies de daninhas, causando ausência desta classe, portanto não sendo avaliado.

Diante do exposto, no segundo ano, os voos ocorreram em dois dias, referente aos estádios fenológicos V2 e V6, correspondendo sequencialmente a 13 e 29 DAS, nas datas: 02 de janeiro e 18 de janeiro, do ano de 2025. Para a geração das imagens aéreas, das áreas de estudo, foi utilizada uma ARP do tipo multirotor/quadrícóptero modelo DJI Phantom 4 Multispectral, Figura 08.


Figura 08 – DJI Phantom 4 Multispectral.



Fonte: Elaboração própria.

Esta ARP é composta por câmera RGB e multiespectral, Figura 09, contendo cinco bandas espectrais – azul ($450\text{ nm} \pm 16\text{ nm}$), verde ($560\text{ nm} \pm 16\text{ nm}$), vermelho ($650\text{ nm} \pm 16\text{ nm}$), borda do vermelho ($730\text{ nm} \pm 16\text{ nm}$) e infravermelho próximo ($840\text{ nm} \pm 26\text{ nm}$) – e resulta em imagens em 2 MP obtidas por um obturador global em um estabilizador triaxial.

Figura 09 – Câmeras do DJI Phantom 4 Multispectral.



Fonte: Adaptado DJI.

A calibração radiométrica desta ARP foi conduzida em condições de campo, previamente ao início dos voos, garantindo a padronização das respostas espectrais adquiridas. O voo do primeiro ano foi realizado com altura de 50 m, resultando em um GSD (Ground Sample Distance) de 2,6 cm. A sobreposição frontal e lateral foram respectivamente, 75% e 70% e a velocidade de 3m/s. No segundo ano o voo foi feito a uma altura de 35 m e um GSD de 1,62 cm. A sobreposição frontal e lateral foram ambas de 80% e a velocidade de 3,1 m/s.

4.2.1 Processamento dos dados obtidos no aerolevanteamento

As imagens coletadas foram, inicialmente, processadas no *software Agisoft Metashape Professional Edition, versão 2.0.0*, licença pessoal, para geração dos ortomosaicos. Posteriormente, visando o processamento das imagens obtidas para aquisição de informações sobre a superfície da terra em estudo, de forma a atribuir classes à cobertura do solo, conforme as configurações espectrais comuns de uma composição de diversas variáveis atribuídas a um ou mais pixels, estes ortomosaicos foram importados no *software ArcGIS, versão 10.8*, utilizando o sistema de referência SIRGAS 2000, Zona 23 S, para a classificação da imagem. As etapas de processamento, classificação e análise espacial foram realizadas no ambiente do *software ArcGIS for Desktop Advanced*, com suporte de módulos especializados, licenciados institucionalmente pelo CTUR/UFRRJ.

No *software ArcGIS*, foi adotada a classificação baseada em pixel considerada como

melhor método para imagens de maior GSD. Sequencialmente foi definida a feição de polígono, irregular, para a determinação das amostras de cada classe de ocupação do solo, efetuando a caracterização das respectivas classes na tabela de atributos. As classes foram: *Zea mays L*, *Cyperus rotundus*, solo e sombra.

Foram definidas 50 amostras por classe, com base nas recomendações de Congalton e Green (2009) para mapas de menos de 1 milhão de acres (404.685,642 hectares) em tamanho, e menos de 12 classes. Em seguida, foi utilizada a ferramenta *Multivariate* do pacote *Spatial Analyst Tools*, a fim de treinar o algoritmo com as amostras determinadas por meio do *Create Signatures*. Na sequência, para geração da imagem classificada, foram utilizados os classificadores: *Maximum Likelihood*, *Random Forest* e *Support Vector Machine*.

O classificador *Random Forest* apresentou parâmetros pré-definidos, tais como, o número máximo de árvores (50), no qual refere-se à quantidade de árvores de decisão que compõem o algoritmo. A profundidade máxima da árvore (30), que indica o número máximo de divisões (níveis) que cada árvore pode ter, permitindo o equilíbrio entre a precisão e a generalização do modelo. E por fim, o número máximo de amostras por classe (1000), no qual garante que cada árvore utilize um número controlado e representativo de exemplos de cada classe, evitando sobreajustes. Os valores destes parâmetros foram mantidos com objetivo do balanço entre a precisão, boa capacidade de aprendizado, maior generalização do modelo e otimização de tempo.

Além disso, tanto para o RF, quanto para o SVM foi necessário determinar os atributos a serem analisados, sendo determinados os atributos de cor e média, para diferenciação entre as classes. Posteriormente, foram geradas amostras em regiões aleatórias na imagem, para a validação entre a classificação e a real classe de ocupação.

Foram calculadas as matrizes de confusão, para apontar o percentual de objetos que foram classificados corretamente ou não, em todas as imagens. A matriz de confusão foi gerada utilizando acurácia balanceada, desta maneira, o peso das classificações foi o mesmo para todas as classes, independente da sua frequência no conjunto de dados, sendo assim o modelo não atinge elevado desempenho apenas por prever a classe majoritária.

Os desempenhos dos classificadores foram expressos em medidas de acurácia global (AG), precisão, *recall* e *F1-score*, como Navarrete et al. (2025). A acurácia global foi utilizada para determinar a proporção total de pixels corretamente classificados em relação ao número total de pixels de referência, como apontado na Equação 1. Já a precisão, foi utilizada para avaliar a probabilidade de um pixel classificado em uma determinada classe realmente pertencer a essa classe no campo, como indicado na Equação 2. O *recall*, foi utilizado para determinar a

proporção de pixels de referência de uma categoria que foram corretamente classificados, como representado na Equação 3, determinando a frequência com que o classificador encontrou as amostras de cada classe, ditando a sensibilidade do modelo. Por fim, o *F1-score*, demonstrado na Equação 4, avaliou a média harmônica entre a precisão e o *recall*, analisando os resultados dentro da faixa de 0 (pior desempenho) a 1 (melhor desempenho) (LIANG, et al. 2020).

$$\text{Acurácia Global} = \frac{\text{Número total de pixels classificados corretamente} \times 100}{\text{Número total de pixels de referência}} \quad \text{Equação (1)}$$

$$\text{Precisão} = \frac{\text{Número de pixels classificados corretamente em cada classe} \times 100}{\text{Número total de pixels classificados naquela classe}} \quad \text{Equação (2)}$$


$$\text{Recall} = \frac{\text{Número de pixels classificados corretamente em cada classe} \times 100}{\text{Número total de pixels de referência naquela classe}} \quad \text{Equação (3)}$$

$$\text{F1 - score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad \text{Equação (4)}$$

. Estas métricas foram utilizadas para avaliar a qualidade da classificação das imagens em cada classificador estudado, e determinar aquele de melhor desempenho, já que as amostras de treinamento foram as mesmas para ML, RF e SVM, em cada estágio fenológico avaliado.

A matriz de confusão e a acurácia global, foram obtidas por meio do uso do pacote *Spatial Analyst Tools*, mediante a ferramenta *Compute Confusion Matrix* no *software ArcGIS*. Já a precisão, *recall* e *F1-score*, foram adquiridos mediante a importação da matriz confusão no *software Rstudio*, utilizando a biblioteca *caret*. O fluxograma apresentado na Figura 10, demonstra de maneira esquemática o processo realizado para obtenção dos resultados de classificação da imagem.

Figura 10 – Fluxograma do processo dos dados obtidos no aerolevanteamento.



Fonte: Elaboração própria.

5 RESULTADOS E DISCUSSÃO


Os resultados dos classificadores ML, RF e SVM foram avaliados para os dois ciclos distintos da cultura, separadamente, de forma a verificar a robustez de cada classificador mediante as diferentes condições, e estádios fenológicos, do milho e da *Cyperus rotundus*.

5.1 Primeiro Ano

5.1.1 Estádio V4


Os resultados da classificação com ML, RF e SVM para o estágio V4, representados, respectivamente, pelas Figuras 11, 12 e 13, evidenciaram que a classe correspondente à *Cyperus rotundus* foi a que apresentou, a maior variabilidade na sua delimitação espacial, enquanto que a classe do solo foi definida em todas as classificações de forma semelhante.

Figura 11 – Classificação *Maximum Likelihood*, do primeiro ano, estágio fenológico V4.




Fonte: Elaboração própria.

Figura 12 – Classificação *Random Forest*, do primeiro ano, estágio fenológico V4.



Fonte: Elaboração própria.

Figura 13 – Classificação *Support Vector Machine*, do primeiro ano, estágio fenológico V4.



Fonte: Elaboração própria.

Analisando as imagens das classificações, no estágio V4, foi possível observar que a classe do solo, compôs maior parte da área, devido ao *Zea mays L.* e a *Cyperus rotundus* estarem

em seu estágio inicial apresentando pouca folhagem, e por isso apresentando maior dificuldade na identificação, já que, quanto maior a exposição do solo maior a interferência causada no desempenho do classificador na determinação das classes (MAIMAITIJIANG et al., 2020). Com base nos resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, apontados na Tabela 02, foi obtido o desempenho do classificador ML.

Tabela 02 – Matriz de confusão: classificação *Maximum Likelihood* do primeiro ano, estágio fenológico V4.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	20	0	4	1	25	0,80	0,54	0,65
Solo	0	24	0	1	25	0,96	0,92	0,94
<i>Cyperus rotundus</i>	15	2	8	0	25	0,32	0,67	0,43
Sombra	2	0	0	23	25	0,92	0,92	0,92
Total	37	26	12	25	100	-	-	-
Acurácia Global	0,75							

Fonte: Elaboração própria.

A acurácia global, foi de 0,75. Isso mostra que o modelo classificou corretamente 75% de todos os pixels das quatro classes, tal valor reflete a dificuldade na separabilidade espectral entre as classes, especialmente *Zea mays L.* e *Cyperus rotundus*.

Na classe *Zea mays L.*, o classificador ML apresentou um valor para a precisão de 0,80, indicando que 80% dos pixels classificados como *Zea mays L.* estavam realmente corretos. No entanto, o *recall* foi de 0,54, ou seja, o modelo conseguiu prever 54% dos pixels que, de fato, pertenciam à esta classe. Essa limitação pode estar relacionada a semelhança espectral entre a classe *Zea mays L.* e *Cyperus rotundus* no estágio V4, o que torna sua distinção mais difícil. O desempenho global é refletido pelo *F1-score* de 0,65, já que esta métrica sintetiza o equilíbrio entre precisão e *recall*: quanto mais próximos de 1 esses valores estiverem, maior será o *F1-score* e consequentemente, maior o desempenho do classificador. Neste caso, o valor intermediário de 0,65, indica que, embora o modelo tenha sido assertivo nas classificações feitas, ele não conseguiu identificar de forma ampla os dados reais da classe.

A classe do solo apresentou na precisão o valor de 0,96 e no *recall* 0,92, o que gera um resultado elevado também para o *F1-score* que foi de 0,94, bem próximo de 1, indicando um excelente desempenho. Este resultado já era esperado, visto que sua assinatura espectral tende a ser distinta no estágio V4, quando ainda há bastante solo exposto.

A classe *Cyperus rotundus* apresentou uma precisão de 0,32, sugerindo que muitos pixels classificados como *Cyperus rotundus* estavam incorretos, o que pode ser associado a confusão com a classe de *Zea mays L.* Por outro lado, o *recall* apresentou o valor de 0,67,

indicando que o classificador conseguiu determinar um maior desempenho em detrimento ao ocorrido na precisão. O *F1-score* reforçou essa assimetria entre a precisão e o *recall*, apresentando um valor de 0,43, reforçando a confusão entre *Zea mays L.* e *Cyperus rotundus* nesse estágio inicial, quando ambas estão pequenas e espectralmente parecidas.

A classe sombra apresentou o valor de 0,92 para precisão, *recall* e *F1-score* mostrando elevado desempenho para esta classe. Isto porque, o comportamento espectral da sombra estava bem definido neste estágio, o que facilitou sua separação das demais classes.

Foi possível verificar que o classificador ML teve alto desempenho para as classes solo e sombra, com métricas próximas de 0,92 e maiores dificuldades na diferenciação entre *Zea mays L.* e *Cyperus rotundus*, o que é explicado pelo fato dessas classes de vegetação apresentarem características próxima em estrutura e cor. Para comparação dos resultados, foi avaliado o desempenho do classificador RF, a partir dos resultados da matriz de confusão, acurácia global, *recall* e *F1-score*, descritos na Tabela 03.

Tabela 03 – Matriz de confusão: classificação *Random Forest* do primeiro ano, estágio fenológico V4.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	21	0	2	2	25	0,84	0,54	0,66
Solo	1	24	0	0	25	0,96	0,86	0,91
<i>Cyperus rotundus</i>	15	4	6	0	25	0,24	0,75	0,36
Sombra	2	0	0	23	25	0,92	0,92	0,92
Total	39	28	8	25	100	-	-	-
Acurácia Global	0,74							

Fonte: Elaboração própria.

O valor da acurácia global foi de 0,74, isso mostra que o modelo classificou corretamente 74% de todos os pixels das quatro classes, bem próximo ao valor obtido com o *Maximum Likelihood* (75%). Portanto, o RF teve desempenho semelhante em termos de acertos globais, mas com diferenças notáveis em cada classe.

Para a classe *Zea mays L.*, o classificador RF apresentou uma precisão superior ao do ML (0,80) correspondendo a 0,84, e um valor igual para o *recall* de 0,54, indicando que o modelo quando classifica *Zea mays L.*, tende a acertar, mas deixa de identificar muitos pixels que realmente são pertencentes a esta classe. O valor para *F1-score* foi de 0,66 refletindo esse desequilíbrio. O comportamento foi semelhante ao do ML, sugerindo uma limitação comum relacionada ao estágio V4, onde o milho ainda não tem forte distinção espectral frente à daninha.

O solo apresentou valores elevados nos resultados, tendo uma precisão de 0,96, *recall* de 0,86, e um *F1-score* de 0,91, tal fato se deve a sua assinatura espectral distinta à vegetação.

Já para a *Cyperus rotundus*, a precisão foi de 0,24, e o *recall* 0,75, ou seja, a maioria dos pixels da daninha foram detectados, mas com baixa precisão (24%). Logo, o RF apresentou tendência de superestimação na atribuição da classe *Cyperus rotundus*, resultando em um número elevado de classificações incorretas, o que comprometeu sua precisão, 15 dos 25 pixels previstos para *Cyperus rotundus* eram na verdade de milho. O *F1-score* mostrou um desempenho baixo para esta classe de 0,36.

Assim como o solo a classe da sombra, apresentou elevado desempenho, tendo em vista sua diferenciação espectral das classes de vegetação. Seus resultados foram compatíveis ao ML, com valores de 0,92 para precisão, *recall* e *F1-score*.

O RF apresentou um padrão geral semelhante ao ML: maior desempenho para solo e sombra, menor para *Zea mays L.* e *Cyperus rotundus*. Reforçando que o estágio V4 ainda tem baixo contraste espectral entre as vegetações, prejudicando a performance dos classificadores. Na Tabela 04, encontram-se os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador SVM.

Tabela 04 – Matriz de confusão: classificação *Support Vector Machine* do primeiro ano, estágio fenológico V4.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	21	0	4	0	25	0,84	0,62	0,71
Solo	0	23	0	2	25	0,92	0,82	0,87
<i>Cyperus rotundus</i>	13	5	6	1	25	0,24	0,60	0,34
Sombra	0	0	0	25	25	1,00	0,89	0,94
Total	34	28	10	28	100	-	-	-
Acurácia Global	0,75							

Fonte: Elaboração própria.

A acurácia global do classificador SVM foi de 0,75, classificando corretamente 75% de todos os pixels das quatro classes, assim como o ML, e ligeiramente superior ao RF (74%). Isto mostra que, mesmo em um estágio precoce como o V4, o SVM conseguiu manter uma performance estável no conjunto dos classificadores.

O modelo foi preciso ao classificar *Zea mays L.*, apresentando um valor de 0,84. No entanto, o *recall* de 0,62 mostrou que 38% dos pixels que realmente eram *Zea mays L.* não foram identificados. Comparado ao ML e RF, o SVM conseguiu um *F1-score* melhor de 0,71 para *Zea mays L.*, revelando maior equilíbrio entre precisão e sensibilidade.

O desempenho para solo foi consistente e elevado, com uma precisão de 0,92, *recall* de 0,82 e *F1-score* de 0,87, mostrando elevada capacidade na identificação da classe solo, como já observado também nos outros modelos.

Para *Cyperus rotundus* a precisão foi de 0,24, indicando uma superclassificação dessa classe, ou seja, o SVM atribuiu erroneamente muitos pixels a *Cyperus rotundus* que na verdade pertenciam a outras classes, especialmente a *Zea mays L.* O *recall* de 0,60 mostrou que o classificador conseguiu recuperar a maior parte dos pixels verdadeiros desta daninha. O *F1-score* de 0,34 reforçou essa assimetria entre acerto e erro, comportamento semelhante ao observado com o RF.

A sombra apresentou uma precisão perfeita (1,00), ou seja, todos os pixels classificados como sombra estavam corretos. O *recall* de 0,89 mostrou que 89% dos pixels de sombra foram encontrados, e o *F1-score* de 0,94 demonstrou o elevado desempenho deste classificador. Isso sinaliza que a sombra mantém sua separabilidade espectral mesmo em estádios iniciais.


Com base na análise comparativa dos três classificadores aplicados no estádio V4, durante o primeiro ano, há dois algoritmos que apresentaram melhor desempenho geral: ML e SVM. Ambos apresentaram maior acurácia global de 75%, sendo que o ML apresentou destaque no valor de *F1-score* para a classe de *Cyperus rotundus*, enquanto o SVM apresentou melhor *F1-score* para classe *Zea mays L.*

Foi possível verificar que no estádio inicial da cultura há maior dificuldade na classificação de milho e daninha concordando com o estudo de Celikkan et al. (2025) que aponta baixa precisão para daninhas em estádios iniciais devido a semelhança espectral com o milho. Já o elevado desempenho para as classes de solo e sombra em todos os classificadores pode ser justificado pela maior homogeneidade espectral dessas superfícies, que facilita sua separação pelos algoritmos. De acordo com Garofalo et al. (2015), classes com assinatura espectral mais pura, como o solo exposto, tendem a apresentar acurácia superior em relação às vegetações em desenvolvimento, devido à menor sobreposição espectral.

5.1.2 Estádio V6


Os resultados da classificação com ML, RF e SVM para o estádio V6, foram representados, respectivamente, pelas Figuras 14, 15 e 16. Sendo possível observar que os classificadores diferenciaram-se na delimitação espacial de todas as classes.

Figura 14 – Classificação *Maximum Likelihood*, do primeiro ano, estágio fenológico V6.




Fonte: Elaboração própria.

Figura 15 – Classificação *Random Forest*, do primeiro ano, estágio fenológico V6.



Fonte: Elaboração própria.

Figura 16 – Classificação *Support Vector Machine*, do primeiro ano, estágio fenológico V6.



Fonte: Elaboração própria.

Avaliando as imagens das classificações, no estágio V6, foi possível verificar que dentre os resultados dos classificadores, o RF foi o que apresentou visualmente maior densidade da classe de *Cyperus rotundus* em toda área da imagem, sugerindo que houve maior confusão desta classe, em seu modelo. Na Tabela 05, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador ML.

Tabela 05 – Matriz de confusão: classificação *Maximum Likelihood* do primeiro ano, estágio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	23	0	1	1	25	0,92	0,61	0,73
Solo	0	25	0	0	25	1,00	1,00	1,00
<i>Cyperus rotundus</i>	15	0	9	1	25	0,36	0,82	0,50
Sombra	0	0	1	24	25	0,96	0,92	0,94
Total	38	25	11	26	100	-	-	-
Acurácia Global	0,81							

Fonte: Elaboração própria.

A acurácia global no estágio V6 com o classificador ML foi de 81%, indicando melhora significativa em relação ao estágio V4 (75%). Com relação a classe *Zea mays L.*, a precisão foi de 0,92, ou seja, acertou 92% das vezes que determinou esta classe. Ainda assim, o *recall* foi de 0,61, indicando que 39% dos pixels de referência pertencentes à classe não foram corretamente identificados. O *F1-score* de 0,73 mostrou melhora em relação ao estágio V4, mas

ainda há limitações para determinar a totalidade da cultura.

Para a classe do solo o ML foi capaz de identificar todos os pixels de solo corretamente, apresentando precisão, *recall*, e *F1-score* com o valor 1,00. A ausência de vegetação sobreposta ou sombreamento excessivo contribui para a estabilidade espectral da classe.

A classe de *Cyperus rotundus* apresentou uma precisão de 0,36, portanto, 36% dos pixels dessa classe foram determinados corretamente, isto reflete, especialmente confusões com *Zea mays L.* O *recall* de 0,82 mostrou que 82% dos pixels reais da classe foram determinados, portanto, apesar da imprecisão o classificador caracterizou de forma elevada esta classe. Este desequilíbrio entre os valores, forneceu um *F1-score* de 0,50.

Já para a sombra o classificador apresentou uma precisão de 0,96, ou seja, 96% dos pixels classificados como sombra realmente pertenciam à classe. Com base no *recall* de 0,92, foi possível observar que o classificador foi capaz de atribuir corretamente 92% dos pixels de referência da classe sombra à sua categoria verdadeira. O *F1-score* de 0,94 confirma o alto equilíbrio entre sensibilidade e especificidade, nesta classe.

Foi possível verificar para o ML um avanço expressivo na acurácia global elevando 6%, em relação ao V4. A classe da *Cyperus rotundus* apresentou melhor *recall* (0,82), e o *Zea mays L.* teve melhora no *F1-score* (0,73). Solo e sombra apresentaram excelente separabilidade, como já esperado. Para o classificador RF, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, na Tabela 06.

Tabela 06 – Matriz de confusão: classificação *Random Forest* do primeiro ano, estádio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	17	1	7	0	25	0,68	0,49	0,57
Solo	1	23	0	1	25	0,92	0,96	0,94
<i>Cyperus rotundus</i>	15	0	6	4	25	0,24	0,43	0,31
Sombra	2	0	1	22	25	0,88	0,81	0,85
Total	35	24	14	27	100	-	-	-
Acurácia Global	0,68							

Fonte: Elaboração própria.

A acurácia global no estádio V6 com RF apresentou o valor de 68%, uma queda em relação ao ML no mesmo estádio (81%), indicando maior número de erros gerais de classificação. Além disso, tal valor é inferior ao encontrado no estádio V4 (74%), mostrando que o avanço fenológico para este classificador não melhorou os resultados. Diante disto, pode-se verificar que a estrutura interna do RF se tornou mais sensível a pequenas variações espectrais ou ruídos entre bandas, prejudicando sua generalização.

A classe *Zea mays L.* apresentou precisão de 0,68, indicando que, entre os pixels classificados como *Zea mays L.*, 68% realmente pertenciam à classe. Apesar disso, o *recall* foi de 0,49, o que evidenciou que mais da metade dos pixels reais da cultura (51%) não foram corretamente reconhecidos pelo classificador, sendo classificado incorretamente como outra classe como *Cyperus rotundus* ou solo. O *F1-score* de 0,57, resultante desse desequilíbrio entre precisão e *recall*, mostrou a limitação do modelo em detectar de forma completa e confiável os alvos da classe milho neste estágio.

Para a classe do solo o RF apresentou leve queda de precisão e *recall*, quando comparado ao ML o que pode indicar que suas árvores de decisão captaram pequenas variações espectrais dentro da classe e as confundiram pontualmente com sombra ou vegetação clara. Ainda assim, o classificador foi 92% preciso, e identificou corretamente 96% dos pixels de solo presentes na referência, mantendo o equilíbrio no valor de *F1-score* de 0,94.

Na *Cyperus rotundus*, assim como no V4, o RF continuou apresentando baixo desempenho para esta daninha, com uma precisão de 0,24, devido a confusão com a classe *Zea mays*, e um *recall* de 0,43. Tais valores contribuíram para um *F1-score* de 0,31, indicando um baixo desempenho.

A sombra manteve o desempenho, com baixa taxa de confusão, principalmente quando comparada às vegetações. A boa separabilidade é mantida mesmo no V6, com maior interferência do dossel sobre o fundo. Apresentou uma precisão de 0,88, *recall* de 0,81 e o *F1-score* de 0,85.

Análises destas mesmas classes, foram realizadas para o classificador SVM com base nos resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, como descrito na Tabela 07.

Tabela 07 – Matriz de confusão: classificação *Support Vector Machine* do primeiro ano, estágio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	17	0	4	4	25	0,68	0,63	0,65
Solo	0	25	0	0	25	1,00	0,96	0,98
<i>Cyperus rotundus</i>	10	1	11	3	25	0,44	0,73	0,55
Sombra	0	0	0	25	25	1,00	0,78	0,88
Total	27	26	15	32	100	-	-	-
Acurácia Global	0,78							

Fonte: Elaboração própria.

A acurácia global no estágio V6 com SVM foi de 78%, sendo um desempenho intermediário entre o ML (81%) e o RF (68%), mostrando que o SVM teve capacidade de

generalização.

Para a classe *Zea mays L.*, foi obtida uma precisão de 0,68, e um *recall* de 0,63, resultando em um equilíbrio entre precisão e sensibilidade. Com base nisto, foi fornecido o valor de 0,65 para *F1-score*, sendo este um desempenho superior ao RF (0,57) e ligeiramente inferior ao ML (0,73). Ainda assim, houve confusão com *Cyperus rotundus* e sombra, indicando que o modelo teve dificuldade em separar o milho de vegetações com espectro semelhante em áreas parcialmente sombreadas.

Para solo apresentou a mesma precisão do ML (100%), um *recall* de 96% e *F1-score* de 0,98, ambos inferiores aos resultados obtidos ao ML que foi de 100% e 1,00, respectivamente, mas superior no *F1-score* do RF (0,94).

Para a *Cyperus rotundus* foi obtida uma precisão de 0,44 e um *recall* de 0,73 mais sensível que o RF (0,43), porém inferior ao ML (0,82), sendo confundida principalmente com a classe de *Zea mays L.* Apresentou um desempenho mediano, já que seu *F1-score* foi de 0,55.

Na classe sombra, o modelo atingiu precisão de 1,00, isto é, todos os pixels classificados como sombra foram corretos. O *recall* apresentou o valor de 0,78, logo, não foram identificados 22% dos pixels reais desta classe. Ainda assim, o *F1-score* de 0,88 confirmou um elevado desempenho geral da classe.


O classificador com melhor desempenho geral no estádio V6, foi o ML, com acurácia global de 81%, além de ter apresentado maior *F1-score* para a classe de *Zea mays L.*, e melhor sensibilidade na classe de *Cyperus rotundus* (maior *recall*), sendo estas as classes de maior importância neste estudo. O SVM foi o segundo melhor classificador em desempenho geral, considerando as quatro classes analisadas e a acurácia global.

Sothe et al. (2017) em abordagem para classificação do estádio sucessional da vegetação com Landsat-8 e RapidEye, confirmou este resultado obtido, quando apontou em seu estudo que os classificadores que apresentaram melhores respostas para vegetação no estádio inicial foram o SVM e o ML, e ainda concluiu que os classificadores apresentaram melhores resultados para vegetação de estádio intermediário à avançado nos casos em que apresentam similaridade espectral.

5.1.3 Estádio V8


Os resultados da classificação com ML, RF e SVM para o estádio V8, mostraram que a medida que os estádios avançaram as delimitações espaciais ocorreram de forma mais semelhante entre os classificadores, quando comparados aos estádios anteriores, conforme foi verificado nas Figuras 17, 18 e 19.

Figura 17 – Classificação *Maximum Likelihood*, do primeiro ano, estágio fenológico V8.




Fonte: Elaboração própria.

Figura 18 – Classificação *Random Forest*, do primeiro ano, estágio fenológico V8.



Fonte: Elaboração própria.

Figura 19 – Classificação *Support Vector Machine*, do primeiro ano, estágio fenológico V8.



Fonte: Elaboração própria.

Avaliando as imagens das classificações, no estágio V8, constatou-se um grande avanço no crescimento foliar do *Zea mays L.* e também na *Cyperus rotundus*, o que reduziu a área de solo exposto em relação aos estádios anteriores, elevando o desempenho dos classificadores. Além disso, foi notável que a classe *Cyperus rotundus* apresentou visualmente diferentes distribuições nos resultados dos classificadores, mantendo, portanto, a dificuldade de discriminação. Na Tabela 08, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador ML.

Tabela 08 – Matriz de confusão: classificação *Maximum Likelihood* do primeiro ano, estágio fenológico V8.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	22	0	2	1	25	0,88	0,81	0,85
Solo	0	25	0	0	25	1,00	1,00	1,00
<i>Cyperus rotundus</i>	5	0	17	3	25	0,68	0,89	0,77
Sombra	0	0	0	25	25	1,00	0,86	0,93
Total	27	25	19	29	100	-	-	-
Acurácia Global	0,89							

Fonte: Elaboração própria.

O classificador ML, no estágio V8, apresentou sua maior acurácia global de 89%, quando comparado ao estágio V4 (75%) e V6 (81%), sendo notável o ganho progressivo de desempenho ao longo dos estádios, com um salto de 14% entre V4 e V8. Esse aumento está diretamente relacionado à evolução do dossel do *Zea mays L.*, que ao se tornar mais adensado

ao longo do tempo, favoreceu a redução de interferência do solo e gerou maior estabilidade espectral da classe *Zea mays L.*

Para a classe *Zea mays L.*, foi apresentada a precisão de 0,88, ou seja, o classificador errou apenas 12% quando determinou esta classe. O *recall* de 0,81 mostrou que o ML estabeleceu com eficiência os pixels reais da cultura, apresentando melhora em relação ao estádio V6 (0,61). O valor do *F1-score* foi elevado correspondendo a 0,85, demonstrando melhor desempenho do que no estádio V6 (0,73).

A classe do solo apresentou classificação perfeita, tendo como resposta para precisão, *recall* e *F1-score* o valor 1,00. O modelo continuou identificando o solo com elevado desempenho, comprovando sua assinatura espectral pura e estável, mesmo com maior cobertura vegetal.

Para a classe de *Cyperus rotundus* a precisão ficou em 0,68, apresentando confusão com a classe do *Zea mays L.* e sombra. O *recall* foi de 0,89, ou seja, o ML conseguiu identificar corretamente 89% dos pixels reais da daninha. O *F1-score* de 0,77, superou o desempenho apresentado nos estádios anteriores para a classe desta daninha.

A classe sombra apresentou precisão perfeita (1,00) e *recall* de 0,86, o classificador não confundiu sombra com nenhuma outra classe, mas deixou de identificar 14% dos pixels reais de sombra. O *F1-score* de 0,93 mostrou o elevado desempenho para essa classe. Para a comparação entre essas análises, na Tabela 09, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador RF.

Tabela 09 – Matriz de confusão: classificação *Random Forest* do primeiro ano, estádio fenológico V8.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	19	0	6	0	25	0,76	0,61	0,68
Solo	0	25	0	0	25	1,00	0,96	0,98
<i>Cyperus rotundus</i>	8	1	14	2	25	0,56	0,64	0,60
Sombra	4	0	2	19	25	0,76	0,90	0,83
Total	31	26	22	21	100	-	-	-
Acurácia Global	0,77							

Fonte: Elaboração própria.

O classificador RF apresentou uma acurácia global de 77%, superior aos valores obtidos anteriormente para o estádio V4 (74%) e V6 (68%), porém inferior a acurácia do ML (89%) neste estádio V8.

Para a classe *Zea mays L.* apresentou uma precisão de 0,76 e um *recall* de 0,61, portanto, acertou 76% dos pixels classificados, e conseguiu identificar 61% dos pixels reais desta classe.

Estes resultados geraram um *F1-score* de 0,68, sendo este desempenho inferior ao do ML (0,85).

A classe do solo manteve o elevado desempenho. Apresentou como resultado de precisão o valor 1,00 e para o *recall* 0,96. Com isso, acertou 100% dos pixels classificados, e identificou 96% dos pixels reais desta classe, resultando em um *F1-score* de 0,98.

A *Cyperus rotundus* apresentou uma precisão de 0,56, resultante principalmente da confusão com *Zea mays L.*, ao passo que o *recall* apresentou um valor de 0,64. O *F1-score* foi de 0,60 inferior ao obtido pelo ML (0,77) no mesmo estágio, demonstrando que o RF não conseguiu aproveitar plenamente o aumento da cobertura vegetal para separar a daninha.

Enquanto a classe da sombra teve uma precisão de 0,76 e *recall* de 0,90, resultando em *F1-score* de 0,83. A classe sombra foi confundida com *Cyperus rotundus* e *Zea mays*, o que pode ser explicado pelo tom mais escuro das folhas e a sobreposição das mesmas devido ao crescimento, mas o desempenho geral foi satisfatório.

Por fim, visando avaliar os três classificadores, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador SVM, na Tabela 10.

Tabela 10 – Matriz de confusão: classificação *Support Vector Machine* do primeiro ano, estágio fenológico V8.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	16	0	3	6	25	0,64	0,67	0,65
Solo	0	25	0	0	25	1,00	0,96	0,98
<i>Cyperus rotundus</i>	6	1	15	3	25	0,60	0,83	0,70
Sombra	2	0	0	23	25	0,92	0,72	0,81
Total	24	26	18	32	100	-	-	-
Acurácia Global	0,79							

Fonte: Elaboração própria.

O classificador SVM apresentou uma acurácia global de 79%, superior aos valores obtidos anteriormente para o estágio V4 (75%) e V6 (78%). É intermediário ao valor de RF (77%) e ML (89%), no estágio V8.

Para a classe *Zea mays L.* o classificador teve uma precisão de 0,64, e apresentou o *recall* de 0,67 (maior valor comparado aos estágios anteriores). O *F1-score* se manteve em 0,65, como no estágio V6, sendo inferior, no estágio V8, ao ML (0,85) e RF (0,68). Considerando o avanço fenológico e o fechamento do dossel no V8, era esperado que o desempenho melhorasse, porém nesta classe ocorreu aumento na confusão com sombra e *Cyperus rotundus*. O SVM apresentou

difficuldade em definir uma fronteira ótima entre *Zea mays L.* e *Cyperus rotundus*, especialmente onde há sombreamento parcial e mistura espectral.

A classe do solo respondeu com resultados idênticos ao do RF com 1,00 de precisão, 0,96 de *recall*, e 0,98 no *F1-score*. Mostrando que o SVM continuou eficiente para classes como o solo.

A classe de *Cyperus rotundus* teve o resultado de 0,60 para precisão, tendo confusões com *Zea mays L.* e sombra. O *recall* de 0,83 mostrou que o classificador conseguiu identificar 83% dos pixels reais da daninha. O *F1-score* de 0,70, foi o segundo melhor entre os três classificadores no V8, com desempenho inferior ao do ML (0,77).

A classe da sombra, teve precisão de 0,92 e *recall* de 0,72, portanto acertou 92% dos pixels classificados, e identificou 72% dos pixels reais desta classe. Apresentou *F1-score* de 0,81, inferior ao do ML (0,93), neste mesmo estádio.

O melhor classificador no estádio V8, foi o ML, tendo em vista que apresentou maior acurácia global e melhor desempenho em todas as classes de vegetação. Se destacou principalmente na detecção de *Cyperus rotundus* (*F1-score* de 0,77), sendo este o melhor resultado para esta classe em todos os estádios avaliados. Essa evolução sugere que, com o avanço fenológico, a separação espectral entre as classes, principalmente entre vegetações, ficou mais nítida.

Wang, Ren e Wu (2024), analisaram séries temporais do índice de área foliar (IAF) em milho com dados de sensores multiespectrais acoplados a ARPs, e verificaram que até o estádio V6, o IAF era geralmente baixo, a partir do V8 ocorria o crescimento acentuado da vegetação, gerando maior cobertura aérea e assinatura espectral mais estável favorecendo a diferença entre milho, solo e sombra. O mesmo é apontado por Ge et al. (2025) que afirmam que com o avanço da cobertura foliar a classificação com algoritmos de aprendizado de máquinas é favorecida. E isto é observado neste estudo, onde no primeiro ano o estádio V8 apresentou os melhores resultados para os classificadores: ML e RF.


Avaliando os estádios V4, V6 e V8 da cultura do milho, e os classificadores ML, RF e SVM, foi possível determinar que o estádio V8 juntamente com o classificador ML, consistiram no melhor resultado. Tendo em vista que ML apresentou crescimento contínuo em seu desempenho ao longo dos estádios, tendo no estádio V8 a melhor resposta para detecção de *Cyperus rotundus* com *recall* de 0,89 e *F1-score* de 0,77. Este resultado pode ser justificado pelo aumento da cobertura do dossel que reduz o ruído espectral do solo e intensifica o contraste entre a cultura e as plantas daninhas, favorecendo o desempenho dos classificadores de imagens (ÑAUNAY et al. 2023).

5.2 Segundo Ano

5.2.1 Estádio V2


Os resultados da classificação com ML, RF e SVM para o estágio V2, no segundo ano, mostraram que a classe do solo, ocupou predominantemente a área, devido ao *Zea mays L.* e a *Cyperus rotundus* apresentarem pouca folhagem como ilustrado, respectivamente, pelas Figuras 20, 21 e 22.

Figura 20 – Classificação *Maximum Likelihood*, do segundo ano, estágio fenológico V2.




Fonte: Elaboração própria.

Figura 21 – Classificação *Random Forest*, do segundo ano, estágio fenológico V2.



Fonte: Elaboração própria.

Figura 22 – Classificação *Support Vector Machine*, do segundo ano, estágio fenológico V2.



Fonte: Elaboração própria.

O estudo de Andrade et al. (2019) apontou que do estágio V2 ao V4, a cultura do milho encontra-se nos estádios iniciais, e devido a isso maior parte da imagem obtida na área do experimento é ocupada por solo descoberto apresentando valores baixos em análises que dependem da vegetação. Na Tabela 11, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador ML.

Tabela 11 – Matriz de confusão: classificação *Maximum Likelihood* do segundo ano, estágio fenológico V2.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	23	2	0	0	25	0,92	0,85	0,88
Solo	0	25	0	0	25	1,00	0,69	0,82
<i>Cyperus rotundus</i>	4	9	10	2	25	0,40	1,00	0,57
Sombra	0	0	0	25	25	1,00	0,93	0,96
Total	27	36	10	27	100	-	-	-
Acurácia Global	0,83							

Fonte: Elaboração própria.

O classificador ML apresentou acurácia global de 83%, no estágio V2. Isso mostra que o modelo classificou corretamente 83% de todos os pixels das quatro classes, mesmo estando no estágio inicial da cultura. Estádios iniciais refletem elevados desempenhos e separabilidade espectral entre as classes, quando o voo é realizado em baixas altitudes, com valores menores de GSD (VELUMANI, 2021).

Para a classe *Zea mays L.*, o ML apresentou elevado desempenho. A precisão de 0,92,

indicou que 92% dos pixels classificados como *Zea mays L.* eram de fato pertencentes à classe. O *recall* de 0,85 evidenciou que foi possível prever 85% dos pixels reais da cultura. Esses valores resultaram em um *F1-score* de 0,88 que demonstrou elevado desempenho para esta classe. Isso indica que, mesmo com folhas pequenas e espaçamento entre plantas ainda evidente, o milho já apresentava assinatura espectral suficientemente distinta para contrastar com o solo exposto.

A classe do solo apresentou precisão de 1,00, logo, todos os pixels classificados como solo estavam corretos. O *recall* foi de 0,69, ou seja, 31% dos pixels reais de solo foram confundidos, majoritariamente com *Cyperus rotundus*, tal confusão pode ser justificada pela baixa biomassa da daninha em meio a grande área de solo exposto. O *F1-score* foi de 0,82 apontando alto desempenho.

Em relação a classe de *Cyperus rotundus*, a precisão correspondeu a 0,40, logo, o classificador acertou apenas 40% dos pixels classificados. Este valor de precisão foi resultante da confusão com pixels que pertenciam originalmente ao solo e *Zea mays L.* Além disso, o classificador se mostrou extremamente sensível, ao identificar 100% dos pixels reais desta classe, já que o valor de *recall* obtido foi 1,00. O *F1-score* resultante foi de 0,57, sendo um desempenho mediano.

Por fim, a classe sombra manteve seu desempenho. Foi obtida uma precisão de 1,00 e *recall* de 0,93. O *F1-score* foi de 0,96, o que corresponde a um elevado desempenho do classificador para esta classe, sendo justificada pela baixa reflectância da sombra, facilmente separável das demais classes, mesmo nos estádios iniciais da cultura. Na Tabela 12, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador RF.

Tabela 12 – Matriz de confusão: classificação *Random Forest* do segundo ano, estágio fenológico V2.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	23	0	2	0	25	0,92	0,74	0,82
Solo	0	25	0	0	25	1,00	0,78	0,88
<i>Cyperus rotundus</i>	8	7	10	0	25	0,40	0,83	0,54
Sombra	0	0	0	25	25	1,00	1,00	1,00
Total	31	32	12	25	100	-	-	-
Acurácia Global	0,83							

Fonte: Elaboração própria.

O classificador RF apresentou uma AG de 83%, equivalente a apresentada pelo ML, no mesmo estágio. A classe *Zea mays L.* teve como resultado uma precisão de 0,92, assim como o

ML. O *recall* foi de 0,74, logo, cerca de 26% dos pixels reais de *Zea mays L.* foram confundidos com outras classes e o *F1-score* foi de 0,82. Tanto o *recall*, quanto o *F1-score* apresentaram valores inferiores aos resultados obtidos para o ML (respectivamente, 0,85 e 0,88).

A classe solo apresentou uma precisão perfeita de 1,00 e um *recall* de 0,78, o que resultou em um *F1-score* de 0,88. Ou seja, todos os pixels classificados como solo estavam corretos, mas cerca de 22% dos pixels reais de solo foram confundidos principalmente com a classe *Cyperus rotundus*, ainda assim o desempenho para esta classe se manteve elevado. Este resultado pode ocorrer devido algumas regiões serem compostas parcialmente por daninha em emergência, gerando assinaturas espectrais ambíguas entre solo exposto e vegetação rala.

A maior limitação do RF, neste estágio, foi com a determinação da *Cyperus rotundus*. Embora tenha atingido um *recall* de 0,83, o modelo obteve precisão de apenas 0,40, resultando em um *F1-score* de 0,54 (o menor entre todas as classes). Isso mostrou que, apesar da elevada capacidade de capturar os alvos reais da *Cyperus rotundus*, o RF superestimou a presença desta classe, confundindo-a com solo e *Zea mays L.* A ausência de um padrão espectral definido desta daninha, aliada à sua baixa densidade e porte reduzido, pode ter induzido os classificadores de árvore a atribuir incorretamente a classe daninha em áreas de transição, especialmente aquelas com pixels mistos.

Já a classe sombra foi identificada com máximo desempenho, gerando um valor para a precisão, *recall* e *F1-score* de 1,00. Isso demonstra que o modelo RF foi extremamente eficaz em detectar essa classe, que tipicamente exibe baixa reflectância em todas as bandas. A separabilidade espectral da sombra tende a ser alta, mesmo em estágios iniciais do ciclo da cultura, o que favorece classificadores baseados em regras de decisão como o RF. Por fim, na Tabela 13, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador SVM.

Tabela 13 – Matriz de confusão: classificação *Support Vector Machine* do segundo ano, estágio fenológico V2.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	20	2	3	0	25	0,80	0,83	0,82
Solo	0	24	0	1	25	0,96	0,69	0,80
<i>Cyperus rotundus</i>	4	9	12	0	25	0,48	0,80	0,60
Sombra	0	0	0	25	25	1,00	0,96	0,98
Total	24	35	15	26	100	-	-	-
Acurácia Global	0,81							

Fonte: Elaboração própria.

O SVM alcançou uma acurácia global de 81%, resultado inferior aos obtidos pelos

classificadores ML (83%) e RF (83%). Na classe do *Zea mays L.*, foi obtida uma precisão de 0,80 e um *recall* de 0,83, portanto, 80% dos pixels classificados como *Zea mays L.* eram de fato pertencentes à classe, e além disso foi possível prever 83% dos pixels reais da cultura. Estes resultados contribuíram para um *F1-score* de 0,82, demonstrando elevado desempenho na separação espectral da cultura mesmo no início do seu desenvolvimento. Quando comparado aos demais classificadores, o SVM teve desempenho igual ao RF (0,82), porém inferior ao ML (0,88).

Para a classe de solo o SVM resultou em uma precisão de 0,96, indicando elevada taxa de acerto. O *recall* foi de 0,69, demonstrando que 31% dos pixels reais de solo não foram reconhecidos, sendo confundidos principalmente com *Cyperus rotundus*. O *F1-score* de 0,80 ficou abaixo do RF (0,88) e do ML (0,82), portanto o desempenho do SVM para esta classe foi o pior entre os classificadores.

Para a *Cyperus rotundus*, o classificador apresentou uma precisão de 0,48, fato explicado novamente pela confusão entre esta classe e principalmente a classe do solo. O *recall* foi de 0,80, então, cerca de 20% dos pixels reais de *Cyperus rotundus* foram confundidos com outras classes. Ao final foi obtido um *F1-score* de 0,60 (o melhor entre os três algoritmos avaliados nesse estágio).

Para a classe sombra a precisão foi no valor de 1,00, e o *recall* de 0,96. O *F1-score* foi de 0,98 caracterizando um desempenho elevado, superior ao apresentado por ML (0,96) mas inferior ao do RF, que apresentou desempenho perfeito (1,00).

Com base na análise dos três classificadores o que apresentou melhor desempenho geral foi o ML, tendo em vista que apesar de seu resultado da acurácia global ser o mesmo do RF (83%), teve melhor desempenho nas classes de maior interesse de diferenciação: *Zea mays L.* e *Cyperus rotundus*. No qual na *Zea mays L.*, obteve o maior *F1-score* (0,88), com excelente equilíbrio entre precisão (0,92) e *recall* (0,85). Enquanto na classe de *Cyperus rotundus* foi o único com *recall* perfeito (1,00), garantindo que nenhum pixel real da daninha fosse omitido.

Kumar et al. (2023) apontou em seu estudo que o SVM e ML foram os algoritmos de aprendizado de máquina que melhor distinguiram culturas como o milho em estágios precoces de crescimento, enquanto o RF teve melhor desempenho para alvos com assinatura espectral estável. Esta análise está em concordância com os resultados obtidos neste estudo, visto que o RF apresentou elevado desempenho na classe do solo e sombra, que são classes de assinatura espectral estável, mas para a classe de plantas o ML foi o que melhor se destacou.

Macedo et al. (2025) explicam que classificadores como o RF e o SVM, dependem de padrões mais definidos ou margens rígidas, e devido a isto apresentam maior dificuldade em


separar classes com variabilidade espectral. Tal fato justifica a dificuldade principalmente do RF em diferenciar as classes de milho e daninha, já que em estádios iniciais, ainda não apresentam suas características espectrais definidas.

A confusão entre a classe de *Cyperus rotundus* e solo, vista em todos os classificadores, neste estágio, pode ser explicada por sobreposição espectral típica dos estádios iniciais, nos quais a vegetação esparsa da daninha é confundida com áreas parcialmente cobertas por solo ou milho recém-emergido. Esses erros de classificação ocorrem frequentemente em pixels localizados nas bordas das plantas, o que diminui a qualidade da informação espectral (LOUARGANT et al., 2018).

5.2.2 Estádio V6


Os resultados da classificação com ML, RF e SVM para o estágio V6, no segundo ano, mostraram que as classificações se assemelham nas delimitações espaciais das classes, como observado, respectivamente, nas Figuras 23, 24 e 25.

Figura 23 – Classificação *Maximum Likelihood*, do segundo ano, estágio fenológico V6.




Fonte: Elaboração própria.

Figura 24 – Classificação *Random Forest*, do segundo ano, estágio fenológico V6.



Fonte: Elaboração própria.

Figura 25 – Classificação *Support Vector Machine*, do segundo ano, estágio fenológico V6.



Fonte: Elaboração própria.

Kumar et al. (2023) afirmaram em seu estudo que modelos de aprendizado de máquina podem prever com elevado desempenho a produtividade do milho de forma eficiente nos estágios de crescimento vegetativo (V6) e reprodutivo (R5), usando índices de vegetação calculados a partir de imagens multiespectrais, obtidas a 30 m de altitude. Neste caso, o desempenho para o classificador ML, no estágio V6, pode ser avaliado com base nos resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, Tabela 14.

Tabela 14 – Matriz de confusão: classificação *Maximum Likelihood* do segundo ano, estágio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	25	0	0	0	25	1,00	0,78	0,88
Solo	0	25	0	0	25	1,00	0,86	0,93
<i>Cyperus rotundus</i>	7	4	13	1	25	0,52	1,00	0,68
Sombra	0	0	0	25	25	1,00	0,96	0,98
Total	32	29	13	26	100	-	-	-
Acurácia Global	0,88							

Fonte: Elaboração própria.

O classificador ML obteve acurácia global de 88% no estágio V6, resultado superior ao V2 (83%). Na classe *Zea mays L.*, a precisão foi de 1,00, ou seja, todos os pixels classificados como *Zea mays L.* realmente pertenciam a esta classe. O *recall* foi de 0,78, indicando que cerca de 22% dos pixels reais da cultura foram confundidos com outras coberturas, principalmente com *Cyperus rotundus*. Esse resultado gerou um *F1-score* de 0,88, evidenciando um ótimo equilíbrio entre sensibilidade e especificidade. A evolução da precisão pode ser atribuída ao aumento da biomassa foliar e maior uniformidade espectral do milho, o que contribui para uma assinatura mais distinta e separável das demais classes.

Para a classe solo, o desempenho também foi notável, com precisão de 1,00 e *recall* de 0,86, resultando em *F1-score* de 0,93. Os resultados mostraram que o solo se manteve uma classe estável e bem definida, e neste caso superou os resultados obtidos para *recall* e *F1-score* no estágio V2 (respectivamente, 0,69 e 0,82).

Já a classe *Cyperus rotundus* evoluiu nos resultados quando comparado ao mesmo classificador no estágio V2. Apresentou uma precisão de 0,52, ainda influenciada pelas confusões com as classes de *Zea mays L.* e solo. O *recall* foi 1,00, o que demonstrou determinação integral dos pixels reais desta classe. E o *F1-score* para a classe foi 0,68. A confusão entre a daninha e o milho nesse estágio pode ser explicada pela estrutura morfológica da daninha, que tende a se expandir lateralmente e a ocupar espaços entre as linhas de cultivo, gerando assinaturas espectrais mistas com o dossel da cultura (LOUARGANT et al., 2018).

A classe sombra manteve resultados com valores elevados, com precisão de 1,00, *recall* de 0,96 e *F1-score* de 0,98. A assinatura espectral característica da sombra, manteve sua consistência mesmo com o adensamento do cultivo, o que favoreceu sua separação. Na Tabela 15, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, referentes ao classificador RF.

Tabela 15 – Matriz de confusão: classificação *Random Forest* do segundo ano, estágio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	<i>Recall</i>	<i>F1 score</i>
<i>Zea mays L.</i>	25	0	0	0	25	1,00	0,89	0,94
Solo	0	25	0	0	25	1,00	0,69	0,82
<i>Cyperus rotundus</i>	3	11	11	0	25	0,44	1,00	0,61
Sombra	0	0	0	25	25	1,00	1,00	1,00
Total	28	36	11	25	100	-	-	-
Acurácia Global	0,86							

Fonte: Elaboração própria.

No estágio fenológico V6, o classificador RF apresentou uma acurácia global de 86%. Para a classe *Zea mays L.*, o classificador alcançou a precisão perfeita, ou seja, valor 1,00, como no ML. O *recall* foi de 0,89, indicando que apenas 11% dos pixels reais da classe foram confundidos, o que revela uma sensibilidade elevada à presença da cultura. Com esses dois indicadores, o *F1-score* atingiu 0,94, o maior valor entre todas as classes, evidenciando que o RF apresentou elevado desempenho na detecção do *Zea mays L.* em V6, superando os valores estabelecidos por ML para esta classe.

Já a classe solo para o RF, apresentou precisão de 1,00 e *recall* de 0,69, resultando em *F1-score* de 0,82. Os valores de *recall* e *F1-score* foram inferiores aos obtidos pelo ML, 0,86 e 0,93, respectivamente.

Na detecção de *Cyperus rotundus*, a precisão foi de 0,44, indicando que 56% dos pixels classificados como *Cyperus rotundus* eram, na verdade, solo ou milho. O modelo apresentou *recall* de 1,00 e um *F1-score* de 0,61, demonstrando houve uma tendência a superclassificar a *Cyperus rotundus*. Por fim, a classe sombra foi classificada com precisão, *recall* e *F1-score* todos iguais a 1,00, um desempenho perfeito. Para análise do classificador SVM, foram apontados os resultados da matriz de confusão, acurácia global, precisão, *recall* e *F1-score*, na Tabela 16.

Tabela 16 – Matriz de confusão: classificação *Support Vector Machine* do segundo ano, estádio fenológico V6.

Classes	<i>Zea mays L.</i>	Solo	<i>Cyperus rotundus</i>	Sombra	Total	Precisão	Recall	<i>F1 score</i>
<i>Zea mays L.</i>	24	0	0	1	25	0,96	0,83	0,89
Solo	1	24	0	0	25	0,96	0,75	0,84
<i>Cyperus rotundus</i>	4	8	13	0	25	0,52	1,00	0,68
Sombra	0	0	0	25	25	1,00	0,96	0,98
Total	29	32	13	26	100	-	-	-
Acurácia Global	0,86							

Fonte: Elaboração própria.

O classificador SVM atingiu uma acurácia global de 86% no estádio V6, igualando o desempenho do RF e se mantendo próximo ao ML (88%). Para a classe *Zea mays L.*, o SVM alcançou uma precisão de 0,96 e *recall* de 0,83, gerando o *F1-score* de 0,89, mostrando a habilidade do modelo em reconhecer esta classe quando bem definida.

A classe solo, por outro lado, apresentou precisão de 0,96, portanto, 96% dos pixels classificados como solo eram de fato pertencentes à classe. O *recall* foi de 0,75, sendo este classificador capaz de identificar 75% dos pixels reais da classe. Por fim, apresentou um *F1-score* de 0,84.

Em relação a *Cyperus rotundus*, o classificador apresentou os mesmos resultados que o ML, gerou uma precisão de 0,52 que revela confusão entre pixels de solo e *Zea mays L.* *Recall* máximo de 1,00 reconhecendo todos pixels reais da daninha. E um *F1-score* de 0,68. Porém, apesar de ser numericamente igual ao ML, sua confusão de classe foi superior para solo, o que não deveria acontecer nesta fase, já que as características estão melhores definidas no comparativo solo e daninha, ao passo que o ML, confundiu com milho apresentando mais coerência para o estádio analisado.

Por fim, a classe sombra, também apresentou os mesmos resultados que o ML, mantendo sua previsibilidade e elevada separabilidade espectral. Alcançou precisão perfeita 1,00 e *recall* de 0,96, gerando um *F1-score* de 0,98, um desempenho excelente e praticamente sem ruído.

Com base na análise comparativa dos três classificadores aplicados no estádio V6, o classificador que apresentou o melhor desempenho geral foi o ML, tendo em vista que resultou em uma maior acurácia global (88%) e precisão perfeita (1,00) para a classe de *Zea mays L.*, apresentando resultados equilibrados entre especificidade e sensibilidade. Resultados semelhantes também foram observados por Zhao et al. (2022), que destacaram a eficácia de algoritmos baseados em variabilidade espectral em estádios específicos do ciclo. O SVM

apresentou resultados próximos, tendo melhor desempenho quando a cultura está mais definida, corroborando os achados de Cozar et al. (2021), os quais indicam que esse classificador tende a ser mais eficiente em fases mais avançadas, quando as assinaturas espectrais são mais estáveis.

Quanto ao grau de distinção entre *Zea mays* L. e *Cyperus rotundus*, o estágio V6 se mostrou o mais propício à diferenciação, com melhora significativa nos *F1-scores* em relação ao V2, o que demonstrou maior separabilidade espectral. Segundo Chivasa et al. (2019), a distinção espectral entre variedades de milho se torna mais acentuada à medida que a planta avança fenologicamente, principalmente em estádios intermediários como o V6, devido ao adensamento foliar que reduz a influência do solo e intensifica o contraste com vegetações de menor porte. Diante disso, reforçam os resultados encontrados consolidando o estágio V6 como o mais eficiente para a discriminação entre a cultura do milho e planta daninha.

A espécie *Cyperus rotundus* apresenta características morfológicas semelhantes ao *Zea mays* L., o que contribui para confusões espectrais e torna a diferenciação entre estas plantas mais tardia (HIRWE et al., 2023). Foi possível perceber na avaliação dos diferentes anos, que a medida que o estágio fenológico da cultura avançou, as classes mais semelhantes foram definindo suas assinaturas espectrais. Todavia, como a presença da *Cyperus rotundus* implica diretamente em competição por espaço, luz e água, quanto mais precoce sua identificação, menor o risco de perda de produtividade sendo importante a consideração desse período de convivência associado a maior confiabilidade dos resultados dos classificadores, como neste trabalho.

5.3 Considerações sobre as safras

No primeiro ano, observou-se que a diferenciação entre o milho (*Zea mays* L.) e a daninha (*Cyperus rotundus*) foi maior no estágio V8, estágio limite para que as plantas daninhas não ofereçam riscos de redução na produtividade. A diferenciação destas classes em estágio mais avançado está associada ao GSD utilizado neste primeiro levantamento, tendo em vista que, quanto maior o valor atribuído a este parâmetro mais difícil é a identificação das classes. Além disso, no primeiro ano, por se tratar do período da safra secundária, o estande foi menor, gerando maior espaçamento entre as plantas do milho, consequentemente maior disponibilidade de áreas para surgimento e crescimento de daninhas, tanto nas entrelinhas quando nas linhas de plantio, dificultando a diferenciação entre as plantas.

No segundo ano os classificadores apresentaram melhor desempenho já nos estádios iniciais da cultura, o que pode estar associado ao menor GSD. Além disso, por se tratar do período da safra principal o estande foi maior, logo, as plantas do milho estavam mais próximas

entre si, reduzindo o espaço para surgimento e crescimento de daninhas, assim como a capacidade competitiva, isto favoreceu maior diferenciação entre essas classes, pois o crescimento da cultura foi favorecido. Este fato é evidenciado na exclusão do estágio V8, do segundo ano, para este estudo, visto que o crescimento de daninhas foi inibido pelo sombreamento da cultura principal.

O desempenho variável dos classificadores evidenciou que não há um modelo único ideal, mas sim uma combinação de condições que favorecem ou limitam sua atuação. O classificador ML demonstrou maior estabilidade diante do cenário proposto. Enquanto o RF se destacou em alvos espectralmente estáveis, como solo e sombra. E o SVM mostrou-se competitivo nas classes vegetais, especialmente em estádios mais avançados.

6 CONCLUSÃO

Os resultados obtidos nos diferentes ciclos da cultura do milho evidenciaram a viabilidade no uso das imagens multiespectrais geradas por Aeronaves Remotamente Pilotadas na detecção de plantas daninhas, especialmente quando associadas a algoritmos de aprendizado de máquina.

No primeiro ano de avaliação, o estágio vegetativo V8 proporcionou melhores condições de separabilidade entre milho e daninha, ao passo que, no segundo ano, o estágio V6 se mostrou mais adequado, considerando as condições espectrais e operacionais de voo.

Em ambos os ciclos, o classificador *Maximum Likelihood* destacou-se com melhor desempenho na distinção entre as classes avaliadas, apresentando elevado potencial para análises baseadas em pixel. Além disso, observou-se que a evolução fenológica da cultura contribuiu para o aumento da separabilidade espectral, favorecendo classificações mais precisas ao longo dos estádios vegetativos.

Conclui-se, portanto, que o uso integrado de imagens multiespectrais, classificadores supervisionados e diferentes estádios fenológicos das culturas é uma abordagem promissora para o manejo agrícola de precisão.

REFERÊNCIAS

- ABBURU, S.; GOLLA, S. B. Satellite image classification methods and techniques: A review. *International journal of computer applications*, v. 119, n. 8, 2015.
- AGISOFT LLC. Agisoft Metashape: versão 2.0.0. Licença pessoal. São Petersburgo, Rússia: Agisoft, 2022. Software.
- ALI, A. et al. Comparative performance of various maize (*Zea mays* L.) cultivars for yield and related attributes under semi-arid environment. *Agricultural and Biological Research*, v. 36, n. 4, p. 63-66, 2020.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische zeitschrift*, v. 22, n. 6, p. 711-728, 2014.
- American Society for Photogrammetry and Remote Sensing. ASPRS Positional Accuracy Standards for Digital Geospatial Data. 2. ed., v.1, 2023.
- ANAC (Agência Nacional de Aviação Civil). Regulamento Brasileiro de Aviação Civil Especial - RBAC - E nº 94. *Diário Oficial da União*. Brasília, 2017.
- ANDRADE, R. G. et al. Monitoring of Corn Growth Stages by UAV Platform Sensors. *Int. J. Adv. Eng. Res. Sci*, v. 6, p. 54-58, 2019.
- ANDREA, M. C. S. et al. Impacts of future climate predictions on second season maize in an agrosystem on a biome transition region in Mato Grosso state. *Revista Brasileira de Meteorologia*, v. 34, p. 335-347, 2019.
- ASIF, M. et al. Mulching improves weeds management, soil carbon and productivity of spring planted maize (*Zea mays* L.). *International Journal of Botany Studies*, v. 5, n. 2, p. 57-61, 2020.
- ASKALE, G. T. et al. Mobile based deep CNN model for maize leaf disease detection and classification. *Plant Methods*, v. 21, n. 1, p. 1-19, 2025.
- BERRÚZ, A. A. A. Factores que regulan la selectividad de los herbicidas. Trabalho de Conclusão de Curso. Universidad Técnica de Babahoyo, 2024, 28p.
- BRETAS, I. L. et al. Detection and mapping of *Amaranthus spinosus* L. in bermudagrass pastures using drone imagery and deep learning for a site-specific weed management. *Agronomy Journal*, 2024.
- BUENO, A. A. et al. Funcionalidades do Uso de Drone na Agricultura Moderna. *Revista Científica Eletrônica de Ciências Aplicadas da FAIT*, p. 1-13, 2023.
- BURKART, N.; HUBER, M. F. A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, v. 70, p. 245-317, 2021.
- CAMARGO, D. C. S. Aplicabilidade do uso de veículos aéreos não tripulados no monitoramento e gestão de unidades de conservação: estudo de caso da estação ecológica do Taim – RS. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, 2018, 132p.

CARMO, E. V. B. Uso de Plantas de Cobertura na Produtividade do Milho no Brejo Paraibano. Trabalho de Conclusão de Curso. Universidade Federal da Paraíba, 2023, 42p.

CAVALCANTE, W. S. S. et al. Tecnologia e inovações no uso de drones na agricultura. *Brazilian Journal of Development*, v.8, n.1, p.7108-7117, 2022.

CELIKKAN, E. et al. WeedsGalore: A multispectral and multitemporal UAV-based dataset for crop and weed segmentation in agricultural maize fields. In: 2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). IEEE, 2025. p. 4767-4777.

CHE'YA, N. N.; DUNWOODY, E.; GUPTA, M. Assessment of weed classification using hyperspectral reflectance and optimal multispectral UAV imagery. *Agronomy*, v. 11, n. 7, p. 1-6, 2021.

CHEN, Z. Investigation on angle of incidence and light reflectance. *Theoretical and Natural Science*, v. 34, p. 33-41, 2024.

CHIVASA, W.; MUTANGA, O.; BIRADAR, C. Phenology-based discrimination of maize (*Zea mays* L.) varieties using multitemporal hyperspectral data. *Journal of Applied Remote Sensing*, v. 13, n. 1, p. 017504-017504, 2019.

COLUSSI, J. et al. Brazil Cuts Its Soybean and Corn Production Projections for 2024. *farmdoc daily*, v. 13, n. 225, 2024.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). Boletim da safra de grãos – 9º levantamento: safra 2024/25. Brasília, DF: Conab, 2025.

CONCENÇO, G. et al. Método ecológico de avaliação da ocorrência de plantas daninhas em áreas de terras baixas do Sul do Brasil. Pelotas: Embrapa, 2024. Comunicado Técnico 402, p 1-10.

CONGALTON, R.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Boca Raton: CRC/Taylor & Francis, 2009. 183p.

COSTA, W. C. A. Caracterização agronômica da cultura do café com auxílio de ferramentas do controle estatístico e sensoriamento remoto terrestre. Dissertação de Mestrado. Universidade Estadual Paulista (Unesp), 2019, 48p.

COZAR, A. M. et al. Recognition of maize phenology in sentinel images with machine learning. *Sensors*, v. 22, n. 1, p. 94, 2021.

CRUSIOL, L. G. T. et al. Conceitos e definições de sensoriamento remoto para monitoramento da soja. Londrina: Embrapa Soja, 2024, Doc. 461, p. 1-42.

DECEA (Departamento de Controle do Espaço Aéreo). ICA 100-40: Aeronaves não tripuladas e o acesso ao espaço aéreo brasileiro. Portaria do DECEA N°112, 2020.

DU, L. et al. Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods. *Scientific Reports*, v. 12, n. 1, p. 15937, 2022.

DUARTE, J. O.; MATTOSO, M. J.; GARCIA, J. C. Milho: Importância Socioeconômica. Sete Lagoas: Embrapa Milho e Sorgo, 2021.

ESRI. ArcGIS Pro: versão 10.8. Software ArcGIS Educational Academic Departmental Medium-Term License. Licença institucional: CTUR/UFRRJ. Redlands, Estados Unidos: Environmental Systems Research Institute, 2025. Software.

FEDONIUK, T. P. et al. Utilizing Remote Sensing Data to Ascertain Weed Infestation Levels in Maize Fields. *Agriculture*, v. 15, n. 7, p. 711, 2025.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. Agricultural production statistics 2010–2023. Roma: FAO, 2024.

GAROFALO, D. F. T. et al. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. *Pesquisa Agropecuária Brasileira*, v. 50, p. 593-604, 2015.

GAŠPAROVIĆ, M. et al. An automatic method for weed mapping in oat fields based on UAV imagery. *Computers and electronics in agriculture*, v. 173, p. 1-12, 2020.

GE, H. et al. Enhancing yield prediction in maize breeding using UAV-derived RGB imagery: a novel classification-integrated regression approach. *Frontiers in Plant Science*, v. 16, p. 1511871, 2025.

GU, J.; CONGALTON, R. G. Assessing the Impact of Mixed Pixel Proportion Training Data on SVM-Based Remote Sensing Classification: A Simulated Study. *Remote Sensing*, v. 17, n. 7, p. 1274, 2025.

JAKELAITIS, A. et al. Efeitos de sistemas de manejo sobre a população de tiririca. *Planta daninha*, v. 21, p. 89-95, 2003.

JOSEPH, A.; DASH, S. K.; RASHEED, K. Proceedings of the Training Programme on Geomatics for Coastal Zone Management. *Fundamentals Of Remote Sensing*, 2016.

JÚNIOR, J. A. L. et al. O uso do sensoriamento remoto na biodiversidade e conservação. *Peer Review*, v. 6, n. 7, 2024.

JÚNIOR, J. A. S.; JÚNIOR, U. J. S.; PACHECO, A. P. Análise de acurácia para o mapeamento de áreas queimadas utilizando uma cena VIIRS 1Km e classificação por Random Forest. *Revista Brasileira de Geografia Física*, v. 14, n. 6, p. 3225-3240, 2021.

KAVZOGLU, T.; TSO, B.; MATHER, P. M. Classification Methods for Remotely Sensed Data. CRC Press, 2024.

KIM, K. et al. Deep Learning of High-Resolution Unmanned Aerial Vehicle Imagery for Classifying Halophyte Species: A Comparative Study for Small Patches and Mixed Vegetation. *Remote Sensing*, v. 15, n. 11, p. 2723, 2023.

KIPKULEI, H. K. et al. Maize yield prediction and condition monitoring at the sub-county scale in Kenya: synthesis of remote sensing information and crop modeling. *Scientific Reports*, v. 14, n. 1, p. 14227, 2024.

KOZLOWSKI, L. A. Período crítico de interferência das plantas daninhas na cultura do milho baseado na fenologia da cultura. *Planta Daninha*, v. 20, p. 365-372, 2002.

- KOZLOWSKI, L. A.; KOEHLER, H. S.; PITELLI, R. A. Épocas e extensões do período de convivência das plantas daninhas interferindo na produtividade da cultura do milho (*Zea mays*). *Planta Daninha*, v. 27, p. 481-490, 2009.
- KUMAR, C. et al. Multi-stage corn yield prediction using high-resolution UAV multispectral data and machine learning models. *Agronomy*, v. 13, n. 5, p. 1277, 2023.
- KUMAR, H. et al. Google's cloud computing platform-based performance assessment of machine learning algorithms for precisely maize crop mapping using integrated satellite data of Sentinel-2A/B and PlanetScope. *Journal of the Indian Society of Remote Sensing*, v. 51, n. 12, p. 2599-2613, 2023.
- LIANG, P. et al. A case-based method of selecting covariates for digital soil mapping. *Journal of Integrative Agriculture*, v. 19, n. 8, p. 2127-2136, 2020.
- LIAO, C. et al. Using spatio-temporal fusion of Landsat-8 and MODIS data to derive phenology, biomass and yield estimates for corn and soybean. *Science of the total environment*, v. 650, p. 1707-1721, 2019.
- LIU, L. et al. High-Resolution Mapping of Maize in Mountainous Terrain Using Machine Learning and Multi-Source Remote Sensing Data. *Land*, v. 14, n. 2, p. 299, 2025.
- LOUARGANT, M. et al. Unsupervised classification algorithm for early weed detection in row-crops by combining spatial and spectral information. *Remote Sensing*, v. 10, n. 5, p. 761, 2018.
- MACEDO, F. L. et al. Assessment of Vegetation Indices Derived from UAV Imagery for Weed Detection in Vineyards. *Remote Sensing*, v. 17, n. 11, p. 1899, 2025.
- MAGALHÃES, P. C.; DURÃES, F. O. M. *Fisiologia da Produção de Milho*. Circular Técnica 76. Sete Lagoas: Embrapa Milho e Sorgo, 2006.
- MAGALHAES, P. C.; SOUZA, T. C. *Cultivo do Milho: Ecofisiologia*. Versão Eletrônica Embrapa Milho e Sorgo, 9ªed., p. 1-33, 2015.
- MAIMAITIJANG, M. et al. Crop monitoring using satellite/UAV data fusion and machine learning. *Remote Sensing*, v. 12, n. 9, p. 1357, 2020.
- MANGANIELI, T. Táticas inovadoras: estratégias eficientes no combate de plantas daninhas na cultura do arroz. *Revista Ciência Rural*, p.1, 2024.
- MARQUES, R. F. et al. Profundidade de semeadura e peso específico das sementes na emergência da planta daninha *Urochloa ruziziensis* em campo. *Revista Brasileira de Ciências Agrárias*, v. 19, n. 1, p. 1-9, 2024.
- MATTIVI, P. et al. Can commercial low-cost drones and open-source GIS technologies be suitable for semi-automatic weed mapping for smart farming? A case study in NE Italy. *Remote sensing*, v. 13, n. 10, p. 1869, 2021.
- MCGUIRK, S. L.; CAIRNS, I. H. Relationships between soil moisture and visible–NIR soil reflectance: A review presenting new analyses and data to fill the gaps. *Geotechnics*, v. 4, n. 1, p. 78-108, 2024.

MENDONÇA, D. A.; REIS, D. O.; FABRICANTE, J. R. Plantas daninhas de culturas agrícolas de importância econômica no município de Itabaiana, SE. *Revista de Ciências Ambientais*, v. 17, n. 1, p. 1-12, 2023.

MKHIZE, Y. et al. Mapping weed infestation in maize fields using Sentinel-2 data. *Physics and Chemistry of the Earth, Parts A/B/C*, v. 134, p. 103571, 2024.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. Sensoriamento e sensores. *Agricultura de precisão*, cap. 5, pp. 119–153. São Paulo: Oficina de Textos, 2015.

MONTEIRO, A.; SANTOS, S.; GONÇALVES, P. Precision agriculture for crop and livestock farming-Brief review. *Animals*, v. 11, n. 8, p. 2345, 2021.

MOSAIC FERTILIZANTES. Fenologia – Estádios Fenológicos. *Nutrição de Safras*, 2021.

MOSSANDE, A. Estudo preliminar sobre o potencial energético da biomassa dos resíduos da cultura do milho (ZEA MAYS L.) na região de Kissomeira, Angola. *Dissertação de Mestrado*. Universidade do Algarve, 2022, 142p.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, v. 66, n. 3, p. 247-259, 2011.

NASCIMENTO, J. et al. Identificação e Mapeamento de Plantas Daninhas em Área de Cultivo de Milho em Douradina-MS. *Revista Brasileira de Agropecuária Sustentável*, v. 14, n. 01, p. 116-126, 2024.

ÑAUNAY, A. F. A. et al. Optimization of soil background removal to improve the prediction of wheat traits with UAV imagery. *Computers and Electronics in Agriculture*, v. 205, p. 107559, 2023.

NAVARRETE, O. L. G.; GARCÍA, A. A.; GRACIA, L. M. N. Evaluation of YOLOv5 Models for Weed Classification in Crops Maize (Zea mays L.). In: *Advancements in Optimization and Nature-Inspired Computing for Solutions in Contemporary Engineering Challenges*. Singapore: Springer Nature Singapore, 2025. p.183-209.

NICOLETTI, A. L. et al. Classificação das Formações da Restinga Catarinense com uso do Algoritmo Random Forest. *Anais do XX Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis, p. 873-876, 2023.

NIE, F. et al. Image identification for two-phase flow patterns based on CNN algorithms. *International Journal of Multiphase Flow*, v. 152, p. 104067, 2022.

OLIVEIRA, M. N. et al. Dinâmica populacional de plantas espontâneas no sistema de plantio orgânico de milho consorciado com lab-lab. *Cadernos de Agroecologia – ISSN 2236-7934 - Anais do XII Congresso Brasileiro de Agroecologia*, Rio de Janeiro, Rio de Janeiro - v. 19, n. 1, 2024.

PANDAY, U. S. et al. A review on drone-based data solutions for cereal crops. *Drones*, v. 4, n. 3, p. 41, 2020.

PEERZADA, A. M. Biology, agricultural impact, and management of *Cyperus rotundus* L.: the world's most tenacious weed. *Acta Physiologiae Plantarum*, v. 39, n. 12, p. 270, 2017.

- PHANG, S. K. et al. From Satellite to UAV-based Remote Sensing: A Review on Precision Agriculture. *IEEE Access*, 2023.
- PHIRI, D. et al. Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, v. 12, p. 1-35, 2020.
- PIAZENTINE, A. E. Períodos de interferência do capim-amargoso na cultura da soja e do milho. Dissertação de Mestrado. Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, 2021, 58p.
- PILECCO, I. B. et al. Potencial e lacunas de produtividade de milho em Santa Catarina. 1 ed. Santa Maria, 2023. 63p.
- QUINTANILLA, C. F. et al. Is the current state of the art of weed monitoring suitable for site-specific weed management in arable crops?. *Weed research*, v. 58, n. 4, p. 259-272, 2018.
- RAWAT, K. S.; KUMAR, S.; GARG, N. Statistical comparison of simple and machine learning based land use and land cover classification algorithms: A case study. *Journal of Water Management Modeling*, 2024.
- REHMAN, F. U. et al. Seed-borne fungal diseases of Maize (*Zea mays* L.): A review. *Agrinula: Jurnal Agroteknologi Dan Perkebunan*, v. 4, n. 1, p. 43-60, 2021.
- ROSSEL, R. V. et al. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, v. 131, n. 1-2, p. 59-75, 2006.
- ROSSETTO, R.; SANTIAGO, A. D. Cana: Plantas daninhas. Brasília: Embrapa, 2022.
- SALMAN, H. A.; KALAKECH, A.; STEITI, A. Random forest algorithm overview. *Babylonian Journal of Machine Learning*, v. 2024, p. 69-79, 2024.
- SARVESTANI, G. S. et al. Early Season Dominant Weed Mapping in Maize Field Using Unmanned Aerial Vehicle (UAV) Imagery: Towards Developing Prescription Map. *Smart Agricultural Technology*, p. 100956, 2025.
- SEFERCIK, U. G. et al. Land Cover Classification Performance of Multispectral RTK UAVs. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 46, p. 489-492, 2021.
- SEN, P. C.; HAJRA, M.; GHOSH, M. Supervised classification algorithms in machine learning: A survey and review. In: *Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018*. Springer Singapore, 2020. p. 99-111.
- SHAH, A. et al. Maize in 2034: A Decade of Growth, Innovation, and Sustainability in Crop Production. *Indus Journal of Bioscience Research*, v. 3, n. 4, p. 62-68, 2025.
- SIATWIINDA, S. M. et al. Climate change impacts on rainfed maize yields in Zambia under conventional and optimized crop management. *Climatic Change*, v. 167, n. 3, p. 39, 2021.
- SILVA, D. V. et al. Growth and yield of maize in purple nutsedge interference. *Semina: Ciências Agrárias, Londrina*, v. 36, n. 5, p. 3077–3084, 2015.

- SILVA, J. R. G.; GUIMARÃES, A. M.; PINOTTI, E. B. Interferência da tiririca nas características agrônômicas e na produtividade do milho de 2ª safra. *Revista Unimar Ciências*, v. 27, n. 1-2, 2018.
- SILVA, W. L.; DEREZYNSKI, C. P. Caracterização climatológica e tendências observadas em extremos climáticos no estado do Rio de Janeiro. *Anuário do Instituto de Geociências*, v. 37, n. 2, p. 123-138, 2014.
- SOTHE, C. et al. Abordagens para classificação do estágio sucessional da vegetação do parque nacional de São Joaquim empregando imagens landsat-8 e rapideye. *Boletim de Ciências Geodésicas*, v. 23, n. 3, p. 389-404, 2017.
- SOUSSI, A. et al. Smart Sensors and Smart Data for Precision Agriculture: A Review. *Sensors*, v. 24, n. 8, p. 2647, 2024.
- STIGLER, S. M. The epic story of su likelihood. *Statistical Science*, p. 598-620, 2007.
- TETILA, E. C. et al. Deep learning models for detection and recognition of weed species in corn crop. *Crop Protection*, p. 107237, 2025.
- THENKABAIL, P. S. et al. Assessing future risks to agricultural productivity, water resources and food security: How can remote sensing help? *PE&RS Photogrammetric Engineering and Remote Sensing*, v. 78, n. 8, p. 773-782, 2012.
- UNIÃO NACIONAL DO ETANOL DE MILHO (UNEM). Projeções da produção de etanol de milho no Brasil (milhões de m³). Cuiabá: UNEM, 2025.
- UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Grain: World Markets and Trade – May 2025. Washington, D.C.: Foreign Agricultural Service, 2025.
- VARGAS, L.; PEIXOTO, C. M.; ROMAN, E. S. Manejo de plantas daninhas na cultura do milho. *Passo Fundo: Embrapa Trigo*, 2006, Doc. 61, p. 1-67.
- VELUMANI, K. et al. Estimates of maize plant density from UAV RGB images using faster-RCNN detection model: Impact of the spatial resolution. *Plant Phenomics*, 2021.
- VENANCIO, L. P. et al. Mapping of corn phenological stages using NDVI from OLI and MODIS sensors. *Semin. Ciênc. Agrar.*, v. 41, p. 1517–1534, 2020.
- VERAMENDI, W. N. C.; CRUVINEL, P. E. Method for maize plants counting and crop evaluation based on multispectral images analysis. *Computers and Electronics in Agriculture*, v. 216, p. 108470, 2024.
- VILLIERS, C. et al. Weed detection in rainfed maize crops using UAV and planetscope imagery. *Sustainability*, v. 15, n. 18, p. 13416, 2023.
- WANG, X.; REN, J.; WU, P. Analysis of Growth Variation in Maize Leaf Area Index Based on Time-Series Multispectral Images and Random Forest Models. *Agronomy*, v. 14, n. 11, p. 2688, 2024.
- WOLFER, M. F. et al. Análise do uso e cobertura da terra utilizando imagens sentinel-2A e inteligência artificial. *Anuário do Instituto de Geociências*, v. 43, n. 4, p. 395-403, 2020.

YANG, C.-C.; PRASHER, S. O.; GOEL, P. K. Differentiation of crop and weeds by decision-tree analysis of multi-spectral data. Transactions of the ASAE, v. 47, n. 3, p. 873-879, 2004.

ZANIN, A. R. A. et al. Reduction of pesticide application via real-time precision spraying. Scientific reports, v. 12, n. 1, p. 5638, 2022.

ZHAO, H. et al. Validating the Crop Identification Capability of the Spectral Variance at Key Stages (SVKS) Computed via an Object Self-Reference Combined Algorithm. Remote Sensing, v. 14, n. 24, p. 6390, 2022.

ZHAO, M. et al. UAV-Multispectral Based Maize Lodging Stress Assessment with Machine and Deep Learning Methods. Agriculture; Basel, v. 15, n. 1, 2025.

ZHU, G.; BLUMBERG, Dan G. Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. Remote sensing of Environment, v. 80, n. 2, p. 233-240, 2002.