

Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”

Imageamento aéreo para aplicação localizada de herbicidas

Ronaldo Sacomani

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Engenharia
de Sistemas Agrícolas

Piracicaba
2024

Ronaldo Sacomani
Engenheiro de Produção Mecânica

Imageamento aéreo para aplicação localizada de herbicidas
versão revisada de acordo com a Resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **THIAGO LIBÓRIO ROMANELLI**

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Engenharia
de Sistemas Agrícolas

Piracicaba
2024

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Sacomani, Ronaldo

Imageamento aéreo para aplicação localizada de herbicidas / Ronaldo Sacomani. - - versão revisada de acordo com a Resolução CoPGr 6018 de 2011. - - Piracicaba, 2024.

51 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Agricultura sustentável 2. Inteligência artificial 3. Detecção de plantas daninhas 4. Matriz de confusão 5. Sensoriamento remoto I. Título

Ao meu pai **José Carlos** (*in memoriam*), minha mãe **Yumi** e minha amada esposa **Saihuri** por toda paciência, confiança, incentivo e carinho durante essa dura jornada,

Dedico.

AGRADECIMENTOS

Agradeço primeiramente a Deus por iluminar meu caminho, me dar saúde e sabedoria para vencer os desafios durante toda a jornada.

Ao professor e orientador Dr. Thiago Libório Romanelli pela paciência, confiança e valiosa ajuda durante esse trabalho.

À Máquinas Agrícolas Jacto pelo auxílio e confiança depositadas.

Aos meus colegas de trabalho Jéssica Costalonga, Thais Lemos e Lucas Silva pela amizade, ajuda e suporte.

À Escola Superior de Agricultura “Luiz de Queiroz” e seus funcionários por todo suporte prestado.

Ao Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas pela oportunidade.

SUMÁRIO

RESUMO.....	6
ABSTRACT	7
LISTA DE FIGURAS	8
LISTA DE TABELAS	9
LISTA DE ABREVIATURAS E SIGLAS	10
1. INTRODUÇÃO.....	11
2. REVISÃO DE LITERATURA.....	13
2.1. O consumo de agrotóxicos e seus impactos	13
2.2. Plantas daninhas e sua importância	14
2.3. Tecnologias para o monitoramento digital de plantas daninhas.....	17
2.4. Aplicações de inteligência artificial na agricultura	19
2.5. Indicadores de desempenho para algoritmos classificadores	21
3. MATERIAL E MÉTODOS.....	23
3.1. Descrição da área	23
3.2. Obtenção e processamento das imagens aéreas georreferenciadas	24
3.3. Coleta dos dados de referência	26
3.4. Análise de desempenho do mapa de aplicação localizada	28
4. RESULTADOS E DISCUSSÃO	33
4.1. Matriz de confusão	33
4.2. Indicadores de desempenho	34
5. CONCLUSÕES	41
REFERÊNCIAS	43

RESUMO

Imageamento aéreo para aplicação localizada de herbicidas

O aumento do uso de agrotóxicos na agricultura tem impactos na saúde humana, nos trabalhadores agrícolas e no ambiente. Nesse contexto, o Objetivo de Desenvolvimento Sustentável 2 (ODS 2), estabelecido pela Organização das Nações Unidas (ONU) promove ações agrícolas sustentáveis, fortalecendo a importância da adoção de estratégias agroecológicas e tecnologias para o manejo localizado de plantas daninhas que reduzam o uso de agrotóxicos sem prejudicar a produtividade agrícola e a produção de alimentos. Diante disso, o uso de aeronaves remotamente pilotadas (ARPs) equipadas com câmeras para aquisição de imagens surge como uma alternativa promissora para o manejo localizado de plantas daninhas, porém, existem desafios tecnológicos a serem superados para a plena adoção dessa tecnologia. Dessa forma, o presente estudo tem como objetivo avaliar o desempenho de um algoritmo classificador na geração de mapas para aplicação localizada de herbicidas. Para produção do mapa de aplicação localizada de herbicidas, foram realizados voos com ARP em áreas comerciais produtoras de soja de primeira safra e milho de segunda safra para aquisição de imagens georreferenciadas. Posteriormente, realizou-se a correção das coordenadas GNSS pelo método cinemático pós-processado (PPK) para obtenção de precisão centimétrica das imagens capturadas. As imagens foram processadas para gerar ortomosaicos, que foram a fonte de entrada para o algoritmo avaliado gerar os mapas de aplicação localizada. Para avaliar os mapas gerados, foram coletados dados de referência em campo para gerar o mapa da verdade de campo, e empregou-se a metodologia da matriz de confusão de duas classes para avaliar o desempenho do algoritmo, permitindo a análise dos números de acertos, erros, cálculo dos indicadores de desempenho, além de verificar a correlação entre o mapa da verdade de campo e o mapa gerado pelo algoritmo. Os resultados dos indicadores de desempenho alcançaram valores médios de 0,78 para precisão, 0,95 para revocação, 0,77 para acurácia, 0,80 para *F-score*, 0,59 para Matthews correlation coefficient (MCC) e 0,56 de coeficiente de correlação linear de Pearson, indicando que o algoritmo teve desempenho superior para identificar plantas daninhas com área projetada no solo maiores que 400 cm². O uso de algoritmos de inteligência artificial (IA) para classificação de imagens aéreas demonstrou ser uma técnica promissora para identificação de plantas daninhas e aplicação localizada de herbicidas. No entanto, são necessários ajustes e aprimoramentos no algoritmo avaliado, visando aperfeiçoar sua precisão e confiabilidade, principalmente para identificação de plantas daninhas com área projetada no solo menores que 400 cm².

Palavras-chave: Agricultura sustentável, Inteligência artificial, Detecção de plantas daninhas, Matriz de confusão, Sensoriamento remoto

ABSTRACT

Aerial imaging for localized herbicide application

The increased use of pesticides in agriculture has impacts on human health, agricultural workers, and the environment. In this context, Sustainable Development Goal 2 (SDG 2), established by the United Nations (UN), promotes sustainable agricultural practices, emphasizing the importance of adopting agroecological strategies and technologies for targeted weed management that reduce pesticide use without compromising agricultural productivity and food production. In this regard, the use of remotely piloted aircraft systems (RPAS) equipped with cameras for image acquisition emerges as a promising alternative for targeted weed management. However, there are technological challenges that need to be overcome for the full adoption of this technology. Therefore, the present study aims to evaluate the performance of a classifier algorithm in generating maps for localized herbicide application. To produce the map for localized herbicide application, RPAS flights were conducted in commercial areas producing first-season soybean and second-season corn for georeferenced image acquisition. Subsequently, the GNSS coordinates were corrected using the post-processed kinematic (PPK) method to obtain centimeter-level accuracy of the captured images. The images were processed to generate orthomosaics, which served as input for the evaluated algorithm to generate the maps for localized application. To evaluate the generated maps, reference data were collected in the field to create the ground truth map, and a two-class confusion matrix methodology was employed to assess the algorithm's performance, allowing for analysis of the numbers of true positives, true negatives, false positives, and false negatives, calculation of performance indicators, and verification of the correlation between the ground truth map and the map generated by the algorithm. The performance indicators yielded average values of 0.78 for precision, 0.95 for recall, 0.77 for accuracy, 0.80 for F-score, 0.59 for the Matthews correlation coefficient (MCC), and 0.56 for the Pearson linear correlation coefficient. These results indicate that the algorithm performed better in identifying weeds with projected areas on the ground larger than 400 cm². The use of artificial intelligence (AI) algorithms for aerial image classification has shown to be a promising technique for weed identification and localized herbicide application. However, adjustments and improvements need to be made to the evaluated algorithm in order to enhance its precision and reliability, especially for identifying weeds with projected areas on the ground smaller than 400 cm².

Keywords: Sustainable agriculture, Artificial intelligence, Weed detection, Confusion matrix, Remote sensing

LISTA DE FIGURAS

Figura 1. Localização das áreas de estudo.....	23
Figura 2. Geometria das áreas experimentais.	23
Figura 3. Principais componenetes do ARP modelo eBee X (Sensefly, Suíça).	24
Figura 4. ARP modelo eBee X (A) e câmara RGB modelo S.O.D.A. (B) (Sensefly, Suíça) utilizados para o imageamento aéreo das áreas experimentais.	25
Figura 5. Receptor GNSS Modelo Spectra SP 60 (Trimble, EUA).	25
Figura 6. Principais etapas para o aerolevanteamento das áreas e processamento das imagens.	26
Figura 7. Coleta dos pontos georreferenciados dos dados de referência em campo.	27
Figura 8. Identificação e classificação das plantas daninhas em campo em função de sua área.	28
Figura 9. Ortomosaicos utilizados para geração de mapas de aplicação localizada de herbicidas por algoritmo classificador.....	29
Figura 10. Matriz de confusão de duas classes para avaliação de mapa de aplicação localizada de herbicidas.	29
Figura 11. Mapas para aplicação localizada de herbicidas gerados por algoritmo classificador.	33

LISTA DE TABELAS

Tabela 1. Influência do GSD no rendimento operacional e na memória, usando uma câmera RGB e com sobreposição lateral e longitudinal das imagens em 65% e 75% respectivamente.	25
Tabela 2. Descrição dos tipos de tratamentos em função do tamanho das plantas daninhas.	27
Tabela 3. Delineamento experimental.	28
Tabela 4. Desempenho do algoritmo classificador utilizando dados obtidos com a matriz de confusão em cada tratamento.	34
Tabela 5. Precisão do algoritmo classificador em cada tratamento.	35
Tabela 6. Revocação do algoritmo classificador em cada tratamento.	36
Tabela 7. Acurácia do algoritmo classificador em cada tratamento.	37
Tabela 8. <i>F-score</i> do algoritmo classificador em cada tratamento.	38
Tabela 9. MCC do algoritmo classificador em cada tratamento.	39
Tabela 10. Coeficientes de correlação linear de Pearson entre os mapas da verdade de campo e aplicação localizada de herbicidas gerados por algoritmo classificador.	40

LISTA DE ABREVIATURAS E SIGLAS

ARP	Aeronave Remotamente Pilotada
CEPEA	Centro de Estudos Avançados em Economia Aplicada
Cfa	Clima subtropical úmido
CNA	Confederação Nacional da Agricultura e Pecuária
CNN	Convolutional Neural Network (Rede Neural Convolucional)
FAO	Food Agriculture Organization of the United Nations (Organização das Nações Unidas para a Alimentação e a Agricultura)
FN	Falso Negativo
FP	Falso Positivo
GNSS	Global Navigation Satellite System (Sistema Global de Navegação por Satélite)
GSD	Ground Sample Distance (Distância da Amostra do Solo)
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
IMEA	Instituto Mato-Grossense de Economia Agropecuária
MCC	Matthews Correlation Coefficient (Coeficiente de Correlação de Matthews)
ML	Machine Learning (Aprendizado de Máquina)
NC	Nível de Confiança
ODM	Objetivos de Desenvolvimento do Milênio
ODS	Objetivos de Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
PIB	Produto Interno Bruto
RGB	Red Green Blue (Vermelho Verde Azul)
RINEX	Receiver Independent Exchange Format (Formato de Intercâmbio Independente do Receptor)
UN DESA	United Nations Department of Economic and Social Affairs (Departamento de Assuntos Econômicos e Sociais das Nações Unidas)
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WHO	World Health Organization (Organização Mundial da Saúde)

1. INTRODUÇÃO

O agronegócio brasileiro exerce um importante papel na economia nacional, contribuindo significativamente com o Produto Interno Bruto (PIB) e gerando emprego para uma parcela relevante da população economicamente ativa. No entanto, a agricultura em larga escala depende amplamente do uso de pesticidas, e os custos associados a essa prática têm aumentado ao longo dos anos. Nesse contexto, o controle eficiente das plantas daninhas desempenha um papel crucial na redução do consumo de agrotóxicos.

O aumento no uso de agrotóxicos pode afetar diretamente a saúde humana e causar envenenamento nos trabalhadores agrícolas, além de apresentar riscos ambientais. Portanto, a utilização de novas tecnologias para a redução do uso de produtos químicos na agricultura é fundamental para promover a agricultura sustentável e alcançar a segurança alimentar e o combate à fome, conforme estabelecido em um dos Objetivos de Desenvolvimento Sustentável (ODS 2), que destaca a importância da promoção da sustentabilidade agrícola. Contudo, é necessário desenvolver estratégias agroecológicas e tecnologias de proteção de plantas que visem à redução do uso de agrotóxicos, sem afetar a produtividade agrícola e a produção de alimentos.

As plantas daninhas representam uma das principais ameaças à produção agrícola, competindo com as culturas por recursos essenciais, como luz, água e nutrientes, além de facilitarem a disseminação de pragas e doenças. O controle fitossanitário adequado das plantas daninhas desempenha um papel crucial na produtividade das colheitas e na redução dos custos de produção. Nesse sentido, o mapeamento preciso das plantas daninhas é uma técnica eficaz para o manejo localizado, permitindo a redução do volume de herbicidas aplicados, uma vez que a distribuição dessas plantas no campo apresenta um perfil heterogêneo.

A digitalização na agricultura tem ganhado cada vez mais destaque, com a utilização de sensores em campo que fornecem dados para sistemas de monitoramento e análise das práticas agrícolas. Esses sensores são capazes de detectar pragas, doenças, plantas daninhas e avaliar o estado nutricional das culturas, utilizando técnicas avançadas de visão computacional e algoritmos de aprendizado de máquina. Além disso, a adoção de tecnologia, incluindo o uso de aeronaves remotamente pilotadas (ARPs) equipadas com câmeras, apresenta potencial para o manejo localizado das plantas daninhas, porém ainda enfrenta desafios tecnológicos a serem superados.

Diante da crescente demanda por aplicação localizada de herbicidas, sem a necessidade de seguir calendários fixos predeterminados, impulsionada pela busca da redução de custos e do impacto ambiental gerado pelas pulverizações, uma alternativa é a utilização de mapas de aplicação confeccionados por algoritmos de inteligência artificial (IA), utilizando ferramentas de sensoriamento remoto para identificar a presença ou a ausência de plantas daninhas no campo. Dessa forma, o presente estudo tem como objetivo avaliar o desempenho de um algoritmo classificador de presença ou ausência de plantas daninhas, analisando e comparando os acertos e erros observados nos mapas de aplicação localizada de herbicidas com os dados amostrados na lavoura.

2. REVISÃO DE LITERATURA

A agricultura é uma importante atividade responsável pela produção dos alimentos, com origem há mais de 10 mil anos, época em que as pessoas produziam alimentos oriundos de ações antrópicas. A agricultura dos dias atuais, conhecida como agricultura moderna ou convencional, é dependente das indústrias de insumos e mais impactante ao ambiente. O aumento da produtividade é a justificativa para a agricultura intensiva ser praticada mundialmente e depender de insumos a base de combustível fóssil (LIMA; SILVA; IWATA, 2019; SAMBUICHI *et al.*, 2017).

Segundo dados do Centro de Estudos Avançados em Economia Aplicada (CEPEA) e da Confederação Nacional da Agricultura e Pecuária (CNA), o agronegócio brasileiro possui importante papel no cenário econômico, sendo que de 2012 até 2021, obteve uma participação média anual de 21% do Produto Interno Bruto (PIB) do Brasil, empregando aproximadamente 18,7 milhões de pessoas, o que corresponde acerca de 20% da população economicamente ativa. Em 2021, o PIB do agronegócio cresceu 8,4% comparado ao ano anterior, e o setor alcançou 27% de participação no PIB do Brasil (CNA; CEPEA, 2022).

A produção e a exportação agrícola do Brasil vêm aumentando a cada ano, no entanto, o uso de agrotóxicos também tem aumentado nas plantações. As culturas de soja, cana-de-açúcar e milho representam 75% do uso total de agrotóxicos no Brasil, que consome em torno de 540 mil toneladas de ingredientes ativos de agrotóxicos e o país gasta aproximadamente US\$ 10 bilhões por ano (VASCONCELOS, 2018).

2.1. O consumo de agrotóxicos e seus impactos

O uso mundial de agrotóxicos apresentou um crescimento de 50% na última década em comparação com a década de 1990, chegando a 7,2 milhões de toneladas de produtos formulados e registrou um mercado global de US\$ 41,1 bilhões em 2020 (FAO, 2022). Esse aumento, pode impactar diretamente na saúde humana, segundo Food Agriculture Organization of the United Nations (FAO) e World Health Organization (WHO), devido aos riscos com a intoxicação causada por agrotóxicos, podendo originar efeitos sociais nos trabalhadores agrícolas (FAO; WHO, 2019).

Os custos com agrotóxicos têm se elevado nos últimos anos, e a sua aplicação para soja transgênica aumentou de 1077,84 R\$/ha na safra de 2021/2022 para 1373,00 R\$/ha na safra 2022/2023 e com expectativa de aumento de 19% nos custos com agrotóxicos para safra 2023/2024 (IMEA, 2023). A expansão na utilização de agrotóxicos é uma questão preocupante, tanto para os custos de produção quanto para a preservação do solo. Além disso, o controle eficiente das plantas daninhas e pragas pode ajudar a diminuir a quantidade utilizada de agrotóxicos (HEINE-FUSTER; ARÁNGUIZ-ACUÑA; RAMOS-JILIBERTO, 2017).

Existem evidências de problemas socioambientais em 194 países, referente à exposição das pessoas aos agrotóxicos e resíduos nos alimentos. A implementação de métodos para redução do uso de produtos químicos na agricultura é de grande importância, visto a necessidade de se adotar técnicas mais sustentáveis para o manejo de pragas e vetores (VAN DEN BERG *et al.*, 2020).

Nos anos 1960, a Revolução Verde foi o marco inicial do uso intensivo de produtos químicos sintéticos (fertilizantes e agrotóxicos) na produção agrícola, com a consolidação das indústrias químicas na agricultura, que após a segunda guerra mundial perceberam na agricultura um mercado promissor para comercialização dos seus

produtos, direcionado para o controle de plantas daninhas, pragas e doenças, motivado pelo incremento de produtividade, necessário para suprir a demanda alimentar da crescente população mundial (LIMA; SILVA; IWATA, 2019). Adicionalmente, as projeções do Departamento de Assuntos Econômicos e Sociais das Nações Unidas (UN DESA) sugerem que a população mundial poderá crescer para cerca de 8,5 bilhões em 2030, 9,7 bilhões em 2050 e 10,4 bilhões de pessoas em 2100 (UN DESA, 2022).

Considerando o crescimento populacional e os impactos que são causados no mundo, ações foram realizadas, por meio de conferências e encontros promovidos pela Organização das Nações Unidas (ONU) na década de 1990, em que foram estabelecidos os Objetivos de Desenvolvimento do Milênio (ODM) para reduzir a pobreza extrema do mundo, entre 2000 e 2015. No decorrer dos anos seguintes, novas estratégias, ações e agendas globais foram desenvolvidas pela ONU, no intuito de fortalecer, conscientizar e concretizar o desenvolvimento sustentável em caráter global. Os ODM conduziram a diálogos e negociações entre chefes de Estado e de Governo que culminaram numa nova agenda, uma nova era pós-2015 chamada de Agenda 2030, composta por 17 Objetivos de Desenvolvimento Sustentável (ODS) e 169 metas, que exige uma nova visão e uma estrutura responsiva, com objetivo de alcançar o desenvolvimento sustentável nas suas três dimensões: econômica, social e ambiental. Dentre estes, o ODS 2 destaca a promoção da agricultura sustentável como forma de aumentar a produtividade e a produção de alimentos, manter os ecossistemas e fortalecer a capacidade de adaptação às mudanças climáticas, possibilitando assim o alcance da segurança alimentar e o combate à fome. (ONU, 2015)

A sustentabilidade do ambiente e da agricultura é afetada pela utilização sistemática dos agrotóxicos, portanto é necessário que sejam criadas estratégias agroecológicas e de tecnologia de proteção de plantas que visem a redução na utilização dos agrotóxicos (LEFÈVRE *et al.*, 2020). Levando em consideração a demanda mundial por uma agricultura mais sustentável, a manutenção dos ecossistemas e a redução dos impactos ambientais negativos, as aplicações sistemáticas de agrotóxicos, com destaque aos herbicidas para o controle de plantas daninhas, são consideradas como pontos negativos para segurança alimentar global (DÉLYE; JASIENIUK; LE CORRE, 2013; GEIGER *et al.*, 2010). Além do que, as plantas daninhas estão se tornando resistentes aos herbicidas, o que requer o desenvolvimento e o avanço tecnológico para realizar o controle, melhorando a sustentabilidade e a viabilidade desta prática. Nestas situações, simplesmente aumentar a dose e aplicar em área total, pode acarretar a elevados custos para os agricultores (WESTWOOD *et al.*, 2018).

2.2. Plantas daninhas e sua importância

Entende-se como planta daninha toda planta invasora ou indesejada presente na área produtiva da cultura de interesse. Esse tipo de planta é considerado como um grave problema na produção agrícola global, afetando na produção de alimentos, fibras e combustíveis, causando perda de rendimento e qualidade da colheita, devido a poluição por sementes, galhos e folhas, interferindo direta ou indiretamente na produtividade agrícola (OERKE, 2006; OWEN, 2016).

As plantas daninhas são capazes de germinar, desenvolver e reproduzir em condições edafoclimáticas desfavoráveis, competem por luz, água, nutrientes e espaço, prejudicando o desenvolvimento da cultura, a produtividade na colheita e facilita o surgimento de pragas e doenças (COLBACH *et al.*, 2021). A capacidade das plantas daninhas em sobreviver em ambientes perturbados, em parte, é devido à sua alta produção de sementes. Além disso, elas geralmente possuem um mecanismo de dormência, que impede a germinação imediata dessas sementes mesmo quando estão em condições adequadas para isso, contribuindo para a perpetuação das espécies

daninhas em cultivos agrícolas, permitindo que elas sobrevivam a adversidades e dificuldades para o seu crescimento vegetativo e reprodutivo (VIVIAN *et al.*, 2008).

O banco de sementes é frequentemente um problema para a agricultura, pois pode causar infestações de plantas daninhas por períodos prolongados, mesmo quando se impede a entrada de novas variedades na área. Apesar do solo agrícola armazenar muito material genético, a variedade de plantas presentes em um momento específico pode não refletir o verdadeiro risco de infestação, uma vez que algumas espécies precisam de circunstâncias especiais para germinar. Contudo, as sementes na superfície do solo também estão propensas a perdas, parasitismo e dispersão. A forma como o solo e as culturas são manejadas tem grande impacto na germinação e diversidade de plantas em uma região, e, conseqüentemente, no banco de sementes (MONQUERO; CHRISTOFFOLETI, 2005). A quantidade das espécies que se acumula no banco de sementes do solo ao longo de várias temporadas influenciará a viabilidade de qualquer estratégia de combate às plantas daninhas (GRUNDY *et al.*, 2004).

As reservas genéticas das plantas daninhas nos solos em áreas agrícolas são classificadas em quatro tipos e divididos em dois grupos principais: transitórios e persistentes. Nos transitórios, as espécies raramente persistem no solo por mais de um ano (MAJOR; PYOTT, 1966; MARAÑÓN; BARTOLOME, 1989), sendo que as sementes destes bancos são normalmente adaptadas a aproveitar espaços abertos resultantes de perturbações previsíveis no tempo. Por outro lado, os bancos persistentes possuem uma fração de sementes com alta capacidade de sobrevivência e podem permanecer viáveis por anos, mantendo-se por períodos prolongados no solo. O grupo de bancos persistentes é geralmente composto por espécies características de ambientes submetidos a distúrbios imprevisíveis no tempo e espaço, mantendo-se em estado latente até que as condições ambientais sejam favoráveis para germinação. Comumente, o banco transitório apresenta uma maior quantidade de sementes acumuladas de espécies anuais e de início de sucessão, enquanto o banco persistente é composto predominantemente por espécies perenes e de final de sucessão (FAVRETO; MEDEIROS, 2004).

A quantificação da produção de sementes das plantas daninhas é muito importante, junto com a classificação visual e as medições associadas a densidade e a biomassa (NORSWORTHY; KORRES; BAGAVATHIANNAN, 2018). Existe uma falta de consenso e padronização na literatura a respeito de como estimar o banco de sementes. Muitos estudos são realizados, mas a escolha da metodologia para a estimativa é frequentemente baseada em pressupostos sem fundamentação científica clara. Isso resulta em uma grande variedade de abordagens e métodos utilizados, dificultando a comparação entre os resultados obtidos em diferentes estudos (MAHÉ *et al.*, 2021).

A avaliação da presença de plantas daninhas, também conhecida como análise de composição florística, fornece informações sobre a presença de plantas indesejadas em uma área específica, influenciada por uma série de fatores, como a natureza da vegetação, as técnicas de cultivo aplicadas e a composição do banco de sementes da área, entre outros aspectos. A diversidade das espécies pode variar conforme a composição de plantas na área, visto que é afetada pelo tipo e a intensidade das práticas de manejo realizadas no local de cultivo (LOPES *et al.*, 2021).

Os estudos fitossociológicos das comunidades de plantas daninhas em sistemas agrícolas ajudam a identificar o momento adequado para o controle ou a convivência das culturas e das plantas daninhas. Por meio dos índices fitossociológicos, é possível determinar qual das espécies de plantas daninhas é mais importante em diferentes fases do desenvolvimento da cultura (CONCENÇO *et al.*, 2013; SANTOS *et al.*, 2016).

O controle fitossanitário das plantas daninhas é uma das práticas mais importantes no sistema de produção agrícola, visto que o manejo inadequado ou ineficaz pode acarretar a redução da produtividade e qualidade do produto final, aumento do custo de produção e, no pior cenário, até inviabilizar a colheita (VITORINO *et al.*,

2017). O controle de plantas daninhas é baseado em três estratégias: evitar a invasão de espécies daninhas (prevenção), remover as plantas invasoras (supressão) e eliminar completamente a planta da área (erradicação). A prevenção impede a chegada e o estabelecimento dessas espécies em uma área, enquanto a supressão utiliza diversos métodos para removê-las, incluindo métodos físicos, mecânicos, culturais, biológicos e químicos. A erradicação é a estratégia mais difícil, pois exige a remoção completa de todas as partes da planta da área (MARTINELLI; ORZARI; FERREIRA, 2019).

A escolha do método para remoção das plantas daninhas é uma decisão importante que deve levar em consideração diferentes fatores, desde o tipo de atividade que está sendo realizada na área, as espécies de plantas daninhas presentes, o relevo, as questões ambientais e econômicas. O controle físico é uma estratégia que utiliza técnicas como o fogo, a cobertura morta, a solarização e a inundação para controlar o crescimento de plantas daninhas. O controle mecânico é feito através de arranquio manual, capina manual, roçada e cultivo mecanizado. Já o controle cultural é realizado através de práticas agrícolas, como rotação de culturas, integração lavoura-pecuária, consórcio de culturas e cobertura do solo durante a entressafra. O controle biológico é uma estratégia que se baseia na pressão dos inimigos naturais sobre as plantas daninhas para controlar seu crescimento. Por fim, o controle químico é realizado por meio do uso de herbicidas e compostos químicos que inibem ou suprimem o crescimento de plantas daninhas (OLIVEIRA *et al.*, 2018).

A tomada de decisão para o controle de plantas daninhas geralmente se baseia em avaliações visuais (VOLL *et al.*, 2003), mas essas avaliações são subjetivas e podem não fornecer uma recomendação precisa para o controle dessas plantas, portanto descrever e mapear a distribuição espacial das espécies invasoras é o primeiro passo para determinar a melhor metodologia para o controle fitossanitário (BALASTREIRE; BAILO, 2001).

Após a identificação das plantas daninhas, é possível escolher qual é a melhor técnica a ser implementada para o controle, seja por meio de métodos físicos, mecânicos, culturais, biológicos, químicos ou integrados (OLIVEIRA; FREITAS, 2008). No entanto, tem-se observado uma maior utilização do método químico nas últimas décadas (FERREIRA *et al.*, 2010).

Conhecer a fecundidade e a capacidade de produção de descendentes das plantas daninhas, associada aos tratamentos com herbicidas, pode ajudar a desenvolver programas de manejo eficazes que impactem a dinâmica populacional das plantas daninhas a longo prazo e reduzam o risco de resistência aos herbicidas (NORSWORTHY; KORRES; BAGAVATHIANNAN, 2018). O efeito a longo prazo de um controle químico sobre a população de plantas daninhas anuais está ligado à diminuição da capacidade de produção de sementes dessas plantas, devido aos tratamentos com herbicidas (GRUNDY *et al.*, 2004). O uso contínuo de herbicidas pode levar a mudanças na composição dessas plantas, favorecendo a seleção de espécies resistentes (MONQUERO; CHRISTOFFOLETI, 2005).

A resistência das plantas daninhas aos herbicidas pode ser definida como a capacidade que algumas espécies dentro da população de plantas têm de sobreviver e se reproduzir mesmo após a exposição a níveis de herbicidas que seriam letais para outros indivíduos da mesma espécie. Essa capacidade é uma característica intrínseca e hereditável presentes em determinados biótipos (CHRISTOFFOLETI; LÓPEZ OVEJERO, 2008). O herbicida não é o causador deste fenômeno que ocorre espontaneamente nas populações de plantas daninhas, mas sim o seletor das espécies resistentes, que eram inicialmente de baixa frequência (CHRISTOFFOLETI; VICTORIA FILHO; SILVA, 1994; LÓPEZ-OVEJERO *et al.*, 2006).

Considerando esse contexto, o mapeamento de plantas daninhas permite inclusive, a adoção de práticas de manejo localizado, o que pode reduzir o volume de herbicidas aplicados (BALASTREIRE; BAILO, 2001). Esse

manejo é possível, visto que as plantas daninhas possuem um perfil heterogêneo de distribuição no campo e podem variar em agregados¹ ou em reboleiras (GERHARDS *et al.*, 1997; LAMB; BROWN, 2001). A geometria e as dimensões desses agregados variam e devem ser considerados para o controle fitossanitário (JOHNSON; MORTENSEN; MARTIN, 1995).

2.3. Tecnologias para o monitoramento digital de plantas daninhas

A digitalização da agricultura é fundamentada na utilização de sensores no campo, sendo que esses dispositivos são responsáveis por fornecer os dados necessários para o desenvolvimento de sistemas de monitoramento agrícola e análise do desempenho das práticas de manejo. Diversos tipos de sensores são utilizados na agricultura para monitorar as lavouras, detectar pragas, doenças, infestação de plantas daninhas e avaliar o estado nutricional da cultura. Em uma das diferentes arquiteturas de solução, os sensores fornecem dados para algoritmos, que por sua vez automatizam a prescrição de insumos agrícolas de maneira localizada (QUEIROZ *et al.*, 2020).

Os sensores para detecção de plantas daninhas podem ser divididos em dois grupos: os que não geram imagens e os que geram imagens (PETEINATOS *et al.*, 2014). No primeiro grupo, os sensores são capazes de medir uma ou mais características em um único ponto da lavoura. Entre as características estão a luz refletida ou emitida pela planta em comprimentos de onda específicos, além da altura da planta acima do solo (GAO *et al.*, 2018). Existem exemplos destes tipos de sensores acoplados a veículos terrestres e usados em sistemas automatizados de aplicação de herbicidas em tempo real (KODALI; RAWAT; BOPPANA, 2014). Para os sensores do segundo grupo, geradores de imagens, as ferramentas de visão computacional são as técnicas mais utilizadas para detecção de plantas daninhas (LIU; BRUCH, 2020). Durante o processamento de imagens adquiridas por câmeras, as características espectrais, morfologia biológica, texturas e padrões espaciais são usados para detectar plantas daninhas e diferenciá-las das plantas cultivadas e do solo. Devido à sua eficiência no reconhecimento e classificação de plantas daninhas, o uso de algoritmos de aprendizado de máquina para extrair características de imagens está aumentando (YU *et al.*, 2019). A variação nas condições de luz, sobreposição de folhas e diferenças não significativas entre plantas daninhas e plantas cultivadas são as limitações para o uso de técnicas de visão de máquina para detecção de plantas daninhas (MAVRIDOU *et al.*, 2019).

Outra técnica baseada em características espectrais é a exposição das folhas à radiação por um intervalo de tempo e intensidade específicos, o que faz com que as folhas emitam radiação fluorescente. A intensidade da fluorescência emitida é altamente dependente das propriedades da folha e do seu estado fisiológico. Portanto, a fluorescência está altamente relacionada às espécies vegetais, o que permite a diferenciação entre as plantas daninhas e a cultura (SU; FENNIMORE; SLAUGHTER, 2019).

Sensores ultrassônicos e sensores de detecção e alcance de luz (*Lidar*) são usados para diferenciar plantas com base em sua altura (PETEINATOS *et al.*, 2014). O sensor ultrassônico pode diferenciar plantas daninhas de folhas largas de gramíneas com base em suas alturas e possui potencial para o uso dessa tecnologia em sistemas autônomos de controle de plantas daninhas. Essa tecnologia pode ser utilizada sozinha ou associada a outras tecnologias de reconhecimento (ANDÚJAR *et al.*, 2011).

A adoção de novas tecnologias tem potencial em trazer melhorias para cada estratégia adotada no manejo de plantas daninhas, reduzindo a necessidade de mão de obra e aumentando a eficiência operacional em comparação

¹ Conjunto de elementos semelhantes agrupados formando uma unidade maior.

com as práticas convencionais. Porém, ainda há alguns desafios tecnológicos que precisam ser superados, como a distinção precisa das plantas daninhas e da cultura. Embora haja esforços promissores em relação ao reconhecimento espectral, a tecnologia ainda não está prontamente disponível. Nesse contexto, o uso de ARPs na inspeção de campo oferece uma oportunidade para o manejo localizado de plantas daninhas (OWEN, 2016).

A utilização de ARPs equipadas com câmeras ou algum outro tipo de sensor para o monitoramento e identificação de plantas daninhas em campo tem se mostrado uma técnica promissora. Esses equipamentos oferecem mais vantagens quando comparados com outras plataformas de sensoriamento remoto, como satélites ou aviões pilotados, pois são capazes de mapear e identificar plantas daninhas de forma precisa, inclusive em dias nublados, visto que podem operar a baixas alturas (PEÑA *et al.*, 2015).

As informações da lavoura passam a ser mais precisas, combinando o uso de tecnologias digitais de mapeamento da infestação de plantas daninhas e identificação de suas espécies com estudos fitossociológicos, que podem prever a composição das sementes no solo e colaborar para melhorar a estratégia de manejo (OLIVEIRA *et al.*, 2020; PEÑA *et al.*, 2015).

Algumas pesquisas com ARPs tem o objetivo de definir e aprimorar o método de controle de plantas daninhas mais adequado e selecionar as práticas de manejo a serem adotadas. Além disso, as imagens obtidas pelos ARPs podem ser usadas para avaliar a eficácia do manejo químico e identificar as áreas onde o controle é necessário (LELONG *et al.*, 2008).

As tecnologias em evolução estão sendo empregadas para o reconhecimento de plantas daninhas e apresentam a capacidade de localizar e identificar por gênero e espécie de plantas daninhas nas áreas entre as linhas do cultivo (LONGCHAMPS *et al.*, 2012; OWEN, 2016). Alguns tipos de sensores são utilizados para identificação das plantas daninhas e aplicação do herbicida em tempo real ou para geração de mapas de infestação de plantas daninhas (LÓPEZ-GRANADOS *et al.*, 2016; FRASCONI *et al.*, 2017). Os sensores podem ser instalados em veículos terrestres ou aéreos. No entanto, nos casos em que a planta daninha está em estágio inicial de desenvolvimento, são necessárias imagens de alta resolução espacial para realizar a detecção. Portanto, há limitações para o reconhecimento de infestação de plantas daninhas usando imagens obtidas por sensores acoplados a veículos aéreos ou satélites (CASTALDI *et al.*, 2017).

A adoção de novas práticas, métodos e tecnologias na agricultura podem reduzir custos e a dependência de insumos sintetizados. A reconfiguração do modelo de agricultura moderna foca nos processos de produção e nas questões ambientais (DOS SANTOS *et al.*, 2022). Neste contexto, a adoção de tecnologia pode contribuir para redução da dependência dos insumos agrícolas e dos custos, com um processo gerencial que utiliza várias ferramentas para a gestão das operações, utilizando dados de diferentes fontes para gerar uma tomada de decisão mais assertiva (BORGES; NASCIMENTO; MORGADO, 2022).

Na agricultura moderna, diversos tipos de sensores são utilizados para controlar de maneira localizada as plantas daninhas. A aplicação do herbicida é feita somente nos locais que as plantas daninhas foram detectadas ou em doses variáveis, de acordo com a espécie, distribuição e nível de infestação (LÓPEZ-GRANADOS, 2011).

2.4. Aplicações de inteligência artificial na agricultura

Uma das principais características da era da Agricultura 4.0² é a utilização de dados digitais. Diversos tipos de dados podem ser capturados por meio de diferentes dispositivos e sensores, possibilitando o desenvolvimento de softwares de visão computacional, eventos acústicos e processamento de dados. Esses softwares são extremamente relevantes para monitorar, compreender e prever diversos aspectos da cadeia produtiva agrícola, a fim de ajudar os produtores rurais com as melhores práticas agrícolas. Em um contexto de obrigatoriedade cada vez maior de uso sustentável dos recursos naturais e aumento da produtividade para garantir a segurança alimentar global, há uma necessidade significativa por melhorias em todas as fases dos processos agrícolas (MEGETO *et al.*, 2020).

O uso de tecnologias sofisticadas auxiliadas por IA e visão computacional são considerados fatores importantes para a crescente adoção da agricultura de precisão e entrada na era da Agricultura 4.0 (LU; YOUNG, 2020). Uma das técnicas que impulsionou o estado da arte da visão computacional é a aprendizagem profunda (LECUN; BENGIO; HINTON, 2015). A maioria dos métodos desenvolvidos para resolver problemas usando imagens e vídeos são baseados em redes neurais convolucionais (CNNs). A grande vantagem do uso de aprendizagem profunda é a menor necessidade de recursos com engenharia, uma vez que as redes neurais profundas são responsáveis por extrair os atributos intrínsecos do problema, como informações de forma, cor e textura. Nos métodos tradicionais de aprendizado de máquina (ML), o desenvolvimento e o uso de atributos artesanais, criados manualmente, podem afetar todo o desempenho do sistema. Além disso, os especialistas precisam criar regras, métodos, formas de destacar e extrair as características intrínsecas ao problema. Os métodos baseados em atributos artesanais são menos robustos as mudanças nos conjuntos de dados, ruído e variabilidade dos dados (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

A relevância dessa tecnologia no contexto da agrícola é a possibilidade de automatizar e otimizar uma infinidade de processos, que podem depender de análises laboratoriais, participação de mão de obra altamente especializada, grande número de trabalhadores ou equipamentos, atividades morosas ou insalubres e procedimentos perigosos para as pessoas. Em geral, para garantir a adoção pelos agricultores, os sistemas devem possuir algumas características, como interoperabilidade, escalabilidade, acessibilidade e usabilidade; no entanto, ainda é um desafio para a maioria das aplicações existentes (ZHAI *et al.*, 2020).

Para uma visão abrangente e em grande escala da área cultivada, um dos formatos de imagem mais comuns é obtido com imageamento aéreo. Esse tipo de imagem pode ser obtido por satélites, aviões e ARPs; as principais vantagens são a coleta de dados de forma não destrutiva e a obtenção sistemática de informações sobre grandes áreas (KAMILARIS; PRENAFETA-BOLDÚ, 2018). Em geral, são produzidas grandes quantidades de imagens, e a avaliação feita por especialistas é normalmente muito morosa, o que pode levar à desatenção e ao erro. Assim, o uso de algoritmos e IA para realizar o reconhecimento de padrões nos dados são essenciais para esse tipo de tarefa (MEGETO *et al.*, 2020).

As imagens de satélite continuam sendo importantes em diversas aplicações na agricultura, como estresse hídrico, biomassa, doenças e estimativa de safras, usando imagens hiperespectrais e índices de vegetação (SISHODIA; RAY; SINGH, 2020). Uma das tarefas de classificação mais comuns é o uso e cobertura da terra, que podem considerar diferentes tipos e escalas de imagens e apresentam bons resultados tanto com técnicas tradicionais de ML quanto com aprendizado profundo (CHENG; HAN; LU, 2017; MA *et al.*, 2019).

² Transformação digital do setor agrícola, com o objetivo de coletar e analisar grandes quantidades de dados para auxiliar na tomada de decisões, sendo comparada à Indústria 4.0.

Uma das principais tendências é o uso da tecnologia diretamente no campo, que está à disposição do agricultor. O uso de dispositivos móveis, como smartphones e câmeras, aumentou a capacidade de monitoramento e coleta de dados. Um exemplo de aplicação prática é o reconhecimento de doenças de plantas por meio de imagens capturadas por smartphones na cultura do trigo (JOHANNES *et al.*, 2017).

O monitoramento visual de pragas feito pelo ser humano em grandes propriedades pode não ser eficaz, e um número crescente de soluções combinam imagens digitais proximais com ML para a detecção e reconhecimento de infestações de pragas. A utilização de armadilhas é a forma mais adotada de monitoramento de pragas e, se executadas corretamente, podem amostrar a população de insetos em uma grande área de interesse. No entanto, sem algum tipo de automação, as armadilhas ainda precisam ser colocadas e coletadas manualmente, ficando suscetível ao erro humano. Assim, independentemente da adoção ou não de armadilhas, há a necessidade de métodos capazes de avaliar o estado das pragas de forma rápida, precisa e autônoma (BARBEDO, 2020).

A detecção automática de plantas daninhas é uma aplicação importante para máquinas autônomas, a qual geralmente utiliza métodos tradicionais de processamento de imagem e ML. Apesar dos resultados promissores com o uso de aprendizagem profunda, o alto custo de criação de um banco de dados é uma barreira para o desenvolvimento comercial de soluções (WANG; ZHANG; WEI, 2019).

No cerne da robótica e da IA, a visão computacional permite a automação de vários processos, desde o plantio até a colheita no ciclo de produção agrícola. No entanto, a escassez de conjuntos de dados de imagens públicas continua sendo um gargalo para prototipagem rápida e avaliação dos algoritmos. Para preencher essa lacuna, algumas iniciativas têm sido realizadas com conjuntos de dados de imagens públicas para controle de plantas daninhas e detecção de frutas (LU; YOUNG, 2020), utilizando imagens aéreas (CHIU *et al.*, 2020) e doenças de plantas (MOHANTY; HUGHES; SALATHÉ, 2016).

O principal desafio da maioria dos conjuntos de dados é que eles são para um problema muito específico. Assim, um gargalo para o desenvolvimento de soluções baseadas em visão computacional é a criação de um banco de dados para treinar algoritmos, visto ao alto custo e morosidade com a participação de especialistas na coleta, verificação, anotação e preparação dos dados, que podem consumir a maior parte do tempo e esforço do projeto. Diferentes técnicas buscam minimizar o uso de dados anotados e aumentar o conjunto de dados para o treinamento dos algoritmos, como por exemplo, pequenas alterações nas imagens originais (SHORTEN; KHOSHGOFTAAR, 2019).

A visão computacional é uma das principais áreas de aplicações de IA e tem como objetivo a criação de algoritmos que ajudem, simulem e até mesmo superem decisões humanas baseadas em dados não estruturados que possam ser interpretados como imagens. Diversos dispositivos e sensores podem ser utilizados para obtenção desse tipo de dado, como câmeras, smartphones e sensores para bandas específicas do espectro eletromagnético. Esses sensores podem ser acoplados a diferentes plataformas, sejam elas fixas a estruturas estáticas ou móveis. No contexto de monitoramento e sensoriamento do campo, os eventos acústicos podem desempenhar um papel importante na detecção de pragas, monitoramento de atividades e estimativa populacional, sem interferir no ambiente (MEGETO *et al.*, 2020).

Essas técnicas podem ser utilizadas para a detecção precoce e monitoramento de pragas, visto que a atividade acústica de insetos pode ser isolada de outros sons ambientais por meio da análise de características nos domínios do tempo e da frequência (PINHAS *et al.*, 2008). Uma solução de baixo custo e em tempo real para a detecção de cigarras em plantações foi proposta por meio da análise de seus padrões sonoros (ESCOLA *et al.*, 2020). O bom desempenho e muitas vezes o baixo custo computacional tornam os sinais acústicos um método altamente

viável para sistemas de detecção e monitoramento das lavouras. O uso de algoritmos ML combinados com sinais acústicos permitirá o desenvolvimento de dispositivos portáteis para monitoramento remoto de atividades de animais e pragas (MEGETO *et al.*, 2020).

2.5. Indicadores de desempenho para algoritmos classificadores

Os modelos de ML são capazes de generalizar a partir de poucos dados disponíveis e realizar previsões robustas, mostrando a importância do processamento de dados e das técnicas de aprendizado de máquina para a previsão da evapotranspiração em áreas onde as medições locais são escassas (ALTHOFF *et al.*, 2018).

O pré-processamento variável é uma etapa muito importante em qualquer problema de aprendizado de máquina, é uma forma de análise usada para detectar e remover ruídos em dados de séries temporais (VAUTARD; YIOU; GHIL, 1992). A utilização de modelos de ML alimentados com dados pré-processados mostrou uma melhor precisão e desempenho do que outros métodos de regressão convencionais (SAHOO *et al.*, 2017).

A maioria das aplicações de IA na agricultura ainda está em um nível de maturidade de prova de conceito, enquanto outros são altamente especializados para uma situação específica. Portanto, as principais características desejadas pelos agricultores, como escalabilidade, acessibilidade e usabilidade não são atendidas. Existem vários desafios para aumentar a adoção de sistemas com IA, mas muitos deles poderiam ser amenizados com mais oportunidades de explorar problemas reais, coletar dados com diferentes sensores, interagir com especialistas experientes, e receber feedback dos usuários sobre como melhorar os sistemas. Os conjuntos de dados agrícolas disponíveis publicamente podem aumentar o interesse na aplicação de técnicas bem-sucedidas de diferentes domínios para problemas agrícolas, reduzir o esforço para coletar e anotar dados e permitir o desenvolvimento e avaliação de algoritmos (MEGETO *et al.*, 2020).

As tarefas de classificação binária podem ser tratadas com eficiência por técnicas de aprendizado de máquina supervisionadas, como redes neurais artificiais (LECUN; BENGIO; HINTON, 2015). A importância de avaliar o desempenho de um algoritmo classificador após o processo de classificação é notado pela existência de um corpus relevante de trabalhos publicados que apresentam possíveis alternativas para essa questão, que incluem o desenvolvimento de novas medidas de avaliação ou a comparação de um subconjunto de métricas já existentes em diferentes casos, para destacar as vantagens e desvantagens de cada métrica utilizada na avaliação do desempenho dos algoritmos (DEMŠAR, 2006; LUQUE *et al.*, 2019).

Em situações em que o objetivo é classificar corretamente uma observação entre dois possíveis grupos, é comum utilizar a matriz de confusão para avaliar o desempenho do modelo. Nela é possível observar como o modelo proposto se comportou diante das classificações feitas, permitindo a análise da quantidade de acertos e erros para cada valor da variável resposta realizada pelo modelo. A matriz de confusão entre dois possíveis grupos é semelhante a uma tabela de frequência de classificação com quatro combinações diferentes de valores previstos e reais. Esses quatro valores podem ser: Verdadeiro Positivo (VP), o que significa que o algoritmo previu positivo e é verdadeiro; Verdadeiro Negativo (VN), o que significa que o algoritmo previu negativo e é verdadeiro; Falso Positivo (FP), o que significa que o algoritmo previu positivo e é falso e Falso Negativo (FN), o que significa que o algoritmo previu negativo e é falso. A partir destes valores, é possível calcular alguns indicadores de desempenho para o algoritmo classificador (FAWCETT, 2006).

De acordo com alguns pesquisadores, a acurácia é a métrica de desempenho mais sensata para avaliar a qualidade de um algoritmo classificador, visto que representa a proporção entre o número de amostras classificadas

corretamente e o número total de amostras (WANG; CHU; XIE, 2007). Por definição, a acurácia pode ser utilizada quando existem mais de duas classes. No entanto, quando o conjunto de dados é desequilibrado, ou seja, o número de amostras em uma classe é muito maior do que o número de amostras na outra classe, a acurácia pode fornecer uma estimativa excessivamente otimista da habilidade do classificador na classe majoritária (SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006).

As medidas de avaliação de modelos que consideram a taxa de acerto não são suficientes para situações em que as classes são desbalanceadas ou possuem relevâncias diferentes entre as classes. O problema de classes desbalanceadas tem se tornado cada vez mais significativo e, por isso, surgiram novas medidas que levam em conta essa questão. Em casos em que o acerto positivo é mais importante do que o acerto negativo, as medidas convencionais não são adequadas para avaliar a performance dos modelos (CHOI *et al.*, 2010).

Para avaliar classificações binárias e suas matrizes de confusão, pode ser empregado diversas taxas estatísticas, de acordo com o objetivo do experimento. Apesar de ser uma questão crucial no aprendizado de máquina, ainda não foi alcançado um consenso generalizado sobre uma medida eletiva unificada. As medidas de Precisão e F1 *Score* calculadas em matrizes de confusão estão entre as métricas mais adotadas em tarefas de classificação binária. No entanto, essas medidas estatísticas podem mostrar resultados inflacionados superotimistas, especialmente em conjuntos de dados desequilibrados. O coeficiente de correlação de Matthews (MCC) é uma taxa estatística mais confiável que produz uma pontuação alta somente se a previsão obteve bons resultados em todas as quatro categorias da matriz de confusão (verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos), proporcionalmente ao tamanho dos elementos positivos e ao tamanho dos elementos negativos no conjunto de dados (CHICCO; JURMAN, 2020). Originalmente desenvolvido para comparação de estruturas químicas (MATTHEWS, 1975), o MCC foi reproposto em 2000 como uma métrica de desempenho padrão para aprendizado de máquina com uma extensão natural para o caso multiclasse (BALDI *et al.*, 2000; GORODKIN, 2004). A eficácia do MCC foi demonstrada em diferentes campos científicos (LIU *et al.*, 2015; NAULAERTS; DANG; BALLESTER, 2017).

Com o aumento no uso e dos custos dos agrotóxicos nos últimos anos, elevou-se também os riscos com as intoxicações, o impacto ambiental e os custos de produção agrícola. Dessa forma, a necessidade de racionalizar o uso de agrotóxicos é um desafio. O controle localizado de plantas daninhas pode ajudar na redução da quantidade utilizada de agrotóxicos durante os tratos culturais e reduzir os impactos negativos provocados durante as pulverizações. Para viabilizar essa abordagem, uma alternativa é utilizar mapas de aplicação localizada de herbicidas que considerem a variabilidade espacial das plantas daninhas na área.

3. MATERIAL E MÉTODOS

3.1. Descrição da área

O experimento foi realizado entre agosto e setembro de 2022 no município de Piraju (23°11'37" S, 49°23'02" W), no estado de São Paulo, em duas propriedades agrícolas (propriedades A e B), como indicado na Figura 1. As áreas experimentais foram compostas por quatro talhões de áreas comerciais produtoras de soja de primeira safra e milho de segunda safra, distribuídos nas duas propriedades, com áreas de 87 ha, 85 ha, 65 ha e 56 ha para os talhões A1, A2, A3 e A4, respectivamente (Figura 2). A altitude média da área é de 646 m e o solo Latossolo Vermelho (SANTOS *et al.*, 2018). O clima regional é subtropical úmido (Cfa), conforme classificação climática de Köppen (1931), com temperatura e precipitação médias anuais de 20 °C e 1283,6 mm, respectivamente.




Figura 1. Localização das áreas de estudo.




Figura 2. Representação das áreas de estudo.

3.2. Obtenção e processamento das imagens aéreas georreferenciadas

A aquisição das imagens georreferenciadas se deu através de voos nos talhões com um ARP de asas fixas modelo eBee X (SENSEFLY, 2019), classe 3, sobrevoando a uma altura média de 110 metros do solo. O equipamento utilizado apresenta as seguintes características: 0,96 m de envergadura; área da asa de 0,25 m²; massa máxima de decolagem de 0,75 kg; faixa de temperatura operacional de -10 a 35 °C; bateria de polímero de lítio de três células; autonomia de voo de 40 minutos; velocidade de cruzeiro de 40 a 90 km/h e resistência ao vento de até 45 km/h. A Figura 3 mostra os principais componentes que compõem o ARP.




Figura 3. Principais componentes do ARP, adaptado do manual eBee X (SENSEFLY, 2019).

Ao ARP (Figura 4 A) foi acoplada uma câmera RGB modelo S.O.D.A de 24 MP do fabricante Sensefly (Figura 4 B), eletronicamente integrada e controlada automaticamente. O plano de voo e as configurações necessárias para aquisição das imagens foram realizados pelo software eMotion 3 (versão 3.14). A sobreposição lateral e longitudinal das imagens foi definida em 65% e 75% respectivamente, para gerar imagens com GSD (*ground sample distance*) de 2,5 cm/pixel. Para definir o GSD, foi levado em consideração o rendimento operacional do voo (ha/h), a quantidade de imagens geradas o que conseqüentemente impacta na memória para armazenamento (GB/ha). A Tabela 1 mostra o impacto do GSD no rendimento operacional e memória necessária.

O momento propício para realizar os voos levou em consideração as condições climáticas, evitando ventos superiores a 36 km/h e dias com previsão de chuva. Os horários dos voos ocorreram entre 10:00 até 14:00 para uma luminosidade o mais uniforme possível, visando padronizar o processo de captura das imagens.




Figura 4. ARP modelo eBee X (A) e câmera RGB modelo S.O.D.A. (B) (SENSEFLY, 2019) utilizados para o imageamento aéreo das áreas experimentais.

Tabela 1. Influência do GSD no rendimento operacional e na memória, usando uma câmera RGB e com sobreposição lateral e longitudinal das imagens em 65% e 75% respectivamente.

GSD (cm/pixel)	Rendimento (ha/h)	Memória (GB/ha)
1,0	44,09	0,56
1,5	64,67	0,26
2,0	88,18	0,15
2,5	107,78	0,10

As imagens obtidas no levantamento aéreo tiveram suas coordenadas GNSS corrigidas pelo método cinemático pós-processado (PPK), conforme Zhang et al. (2019), utilizando o receptor GNSS do fabricante Trimble, modelo Spectra SP 60 (Figura 5) como base durante a realização dos voos.



Figura 5. Receptor GNSS Modelo Spectra SP 60 (TRIMBLE, 2016).

A base para coleta estática com o receptor GNSS modelo SP60 foi instalada durante todos os voos em locais limpos e livres de obstáculos que poderiam interferir na recepção do sinal dos satélites. Foi utilizado o aplicativo Survey Mobile para realizar a configuração do receptor GNSS, que realizou a coleta estática de no mínimo três horas a cada voo realizado.

Após os voos e a espera do tempo mínimo de levantamento das coordenadas GNSS da base, retiraram-se os dados do receptor GNSS referente ao dia do monitoramento. Para o acesso a memória interna da SP60, foi utilizado o software Spectra File Manager.

Assim que coletado os dados da SP60, realizou-se a conversão dos arquivos para o formato RINEX (*Receiver Independent Exchange Format*), cujo objetivo é permitir que os dados coletados por diferentes receptores GNSS possam ser processados e analisados por diferentes programas de pós-processamento, independentemente do fabricante do receptor ou da marca do software de pós-processamento. Foi utilizado o serviço online para pós-processamento de dados GNSS do Instituto Brasileiro de Geografia e Estatística (IBGE, 2022). As informações do relatório do posicionamento por ponto, fornecidas após o processamento dos dados pelo IBGE foram utilizadas no software eMotion 3 (versão 3.14) para realizar a correção das coordenadas GNSS das imagens capturadas durante os voos.

Por fim, a última etapa do processo foi a geração do ortomosaico, que é uma imagem georreferenciada criada a partir da fusão das várias imagens aéreas capturadas durante o voo. O processamento das imagens para geração do mosaico georreferenciado foi realizado no software PIX4D fields.

Na Figura 6 é apresentado o fluxograma das principais etapas executadas para geração do ortomosaico com coordenadas GNSS precisas.




Figura 6. Principais etapas para o aerolevanteamento das áreas e processamento das imagens.

3.3. Coleta dos dados de referência

Por meio do método de caminhada, foi realizada a coleta de dados de referência, também chamada de verdade de campo, após o término de cada voo nas áreas de estudo. Os dados de referência coletados corresponderam a presença de plantas daninhas (positivo) e a ausência (negativo) observadas em campo para cada ponto amostral. A navegação e marcação dos pontos georreferenciados na área se deu utilizando o receptor GNSS SP60, por meio do aplicativo Survey Mobile que é acessado por smartphone. A SP60 operou com precisão centimétrica, por meio correção por satélite RTX Center Point (TRIMBLE, EUA), que fornece uma precisão média de 2,5 cm, segundo dados do fabricante (Figura 7).



Figura 7. Coleta dos pontos georreferenciados dos dados de referência em campo.

Foram definidos 3 tratamentos em função do tamanho das plantas daninhas, e os tamanhos classificados em função de sua área: Pequena (P) com uma área projetada no solo (vista de cima) de até 400 cm²; Média (M), com áreas maiores que 400 e menores 900 cm² e Grande (G), com áreas superiores a 900 e até 1600 cm² (Tabela 2). Em cada ponto amostral de presença foi realizado a identificação e classificação da planta, utilizando gabaritos com áreas de 400 cm², 900 cm² e 1600 cm² para auxiliar na classificação, conforme a Figura 8.

Tabela 2. Descrição dos tipos de tratamentos em função do tamanho das plantas daninhas.

Tratamento	Descrição	Área projetada no solo (cm ²)
T1 - PDP	Tratamento 1 - Plantas daninhas pequenas	≤ 400
T2 - PDM	Tratamento 2 - Plantas daninhas médias	$400 > \text{área} \leq 900$
T3 - PDG	Tratamento 3 - Plantas daninhas grandes	$900 > \text{área} \leq 1600$




Nome Popular	Nome científico	Imagem	Classe	Área projetada no solo (cm ²)
Buva	<i>Conyza bonariensis</i>		P	≤ 400
Guanxuma	<i>Sida rhombifolia</i>		M	400 > área ≤ 900
Guanxuma	<i>Sida rhombifolia</i>		G	≥ 900 área ≤ 1600

Figura 8. Identificação e classificação das plantas daninhas em campo em função de sua área.

Foi utilizado o delineamento em blocos casualizados, em que cada área representa um bloco, sendo o experimento composto por quatro blocos e três tratamentos, considerando plantas daninhas pequenas, médias e grandes. A execução do plano amostral por tratamento se deu realizando a coleta de 30 amostras, sendo 15 de presença e 15 de ausência em cada bloco, totalizando 120 parcelas por tratamento e 360 no total (Tabela 3).

Tabela 3. Delineamento experimental.

Tratamento	Áreas (Blocos)								Total de amostras
	A1		A2		A3		A4		
	Positivo	Negativo	Positivo	Negativo	Positivo	Negativo	Positivo	Negativo	
T1 - PDP	15	15	15	15	15	15	15	15	120
T2 - PDM	15	15	15	15	15	15	15	15	120
T3 - PDG	15	15	15	15	15	15	15	15	120

3.4. Análise de desempenho do mapa de aplicação localizada

Os ortomosaicos (Figura 9) com coordenadas GNSS com precisão centimétrica das quatro áreas experimentais, gerados com as imagens do aerolevanteamento, foram disponibilizadas para a empresa “A” gerar os mapas de aplicação localizada de herbicidas.




Figura 9. Ortomosaicos utilizados para geração de mapas de aplicação localizada de herbicidas por algoritmo classificador.

Para avaliar o mapa de aplicação localizada de herbicidas foi utilizada a matriz de confusão, que oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas e as classificações preditas para cada classe em um determinado conjunto de dados, dessa forma permitiu uma análise mais detalhada do que a mera proporção de classificações corretas. A matriz de confusão é reconhecida como uma das mais importantes métricas de avaliação de produtos de dados de sensoriamento remoto (STORY; CONGALTON, 1986).

Os vetores de ponto do mapa verdade de campo e do mapa gerado pelo algoritmo classificador foram exportados para o software QGIS Desktop (versão 3.10.12) para avaliação das classificações realizadas pelo algoritmo. A Figura 10 mostra matriz de confusão para duas classes, presença ou ausência de planta daninha. A classificação atual, contém o mapa da verdade de campo, confeccionado a partir dos dados reais amostrados em solo, enquanto a classificação prevista contém o mapa de aplicação localizada que foi avaliado.

		Classificação Atual Mapa da Verdade de Campo	
		Presença de Planta Daninha Positivo	Ausência de Planta Daninha Negativo
Classificação Prevista Mapa de Aplicação Localizada	Presença de Planta Daninha Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Ausência de Planta Daninha Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Figura 10. Matriz de confusão de duas classes para avaliação de mapa de aplicação localizada de herbicidas.

As medidas de desempenho para o mapa de aplicação localizada foram produzidas a partir da análise da matriz de confusão:

Verdadeiro Positivo (VP): corresponde que no mapa de aplicação localizada (classificação prevista), em um dado local de coordenadas “x,y” indicou presença de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi evidenciado presença.

Verdadeiro Negativo (VN): corresponde que no mapa de aplicação localizada, em um dado local de coordenadas “x,y” indicou ausência de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi constatado ausência.

Falso Positivo (FP): corresponde que no mapa de aplicação localizada, em um dado local de coordenadas “x,y” indicou presença de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi evidenciado ausência.

Falso Negativo (FN): corresponde que no mapa de aplicação localizada, em um dado local de coordenadas “x,y” indicou ausência de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi constatado presença.

Utilizando os valores de VP, VN, FP e FN obtidos na matriz de confusão, foi possível calcular e analisar os indicadores de desempenho do algoritmo classificador, conforme as equações de Precisão (Eq. 1), Revocação (Eq. 2), Acurácia (Eq. 3), *F-score* (Eq. 4) e MCC (Eq. 5):

$$\text{Precisão} = \frac{VP}{VP+FP} \quad (1)$$

$$\text{Revocação} = \frac{VP}{VP+FN} \quad (2)$$

$$\text{Acurácia} = \frac{VP+VN}{VP+VN+FP+FN} \quad (3)$$

$$F\text{-score} = \frac{(2 \times \text{Precisão} \times \text{Revocação})}{(\text{Precisão} + \text{Revocação})} \quad (4)$$

$$\text{MCC} = \frac{(VP \times VN) - (FP \times FN)}{\sqrt{(VP+FP) \times (VP+FN) \times (VN+FP) \times (VN+FN)}} \quad (5)$$

Além da matriz de confusão e dos indicadores de desempenho, foi realizada a análise de correlação linear de Pearson, com o objetivo de avaliar a validade e a confiabilidade dos mapas de aplicação localizada gerados pelo algoritmo utilizado neste estudo, comparando-os com os mapas da verdade de campo em relação às quantidades de positivos e negativos em cada um dos três tratamentos.

O coeficiente de correlação de Pearson (r) é um número que possibilita avaliar o grau de correlação entre duas variáveis, representando a intensidade da relação linear entre essas variáveis em análise. É um valor adimensional, que pode ser positivo (+) indicando que é diretamente proporcional ou negativo (-) indicando que é inversamente proporcional. Quando o coeficiente de correlação linear de Pearson (r) é igual a 0, indica que as duas variáveis não apresentam dependência linear uma em relação à outra. No entanto, quando o valor de r é igual a 1, significa que há uma correlação positiva, ou seja, as duas variáveis estão proporcionalmente relacionadas entre si. As magnitudes das correlações podem ser definidas como: pequena ($0,10 < |r| \leq 0,29$), média ($0,30 < |r| \leq 0,49$), grande ($|r| > 0,50$) (COHEN, 1988).

Foram geradas três matrizes de correlação linear de Pearson, referentes às presenças das plantas daninhas e às ausências, uma para cada um dos três tratamentos. A análise foi realizada utilizando o software Minitab (versão

19.2020.1), com um nível de confiança (NC) de 95% entre os mapas e a significância de “r” verificada com probabilidade de 5%.

A análise de correlação é uma técnica estatística amplamente utilizada para avaliar a concordância entre dois conjuntos de dados e determinar a força da relação entre eles. No contexto deste estudo, a correlação entre os mapas de aplicação localizada e os mapas da verdade de campo indica a precisão do algoritmo em identificar corretamente a presença ou ausência de plantas daninhas em cada tratamento.

4. RESULTADOS E DISCUSSÃO

Os resultados deste trabalho permitiram avaliar os mapas para aplicação localizada de herbicidas (Figura 11) gerados por algoritmo classificador a partir da identificação de plantas daninhas em ortomosaicos com GSD de 2,5 cm/pixel, utilizando imagens aéreas georreferenciadas com precisão centimétrica, obtidas por uma câmera RGB acoplada em um ARP. Após realizados todos os tratamentos, foi possível gerar a matriz de confusão e calcular os indicadores de desempenho, obtidos em cada tratamento.

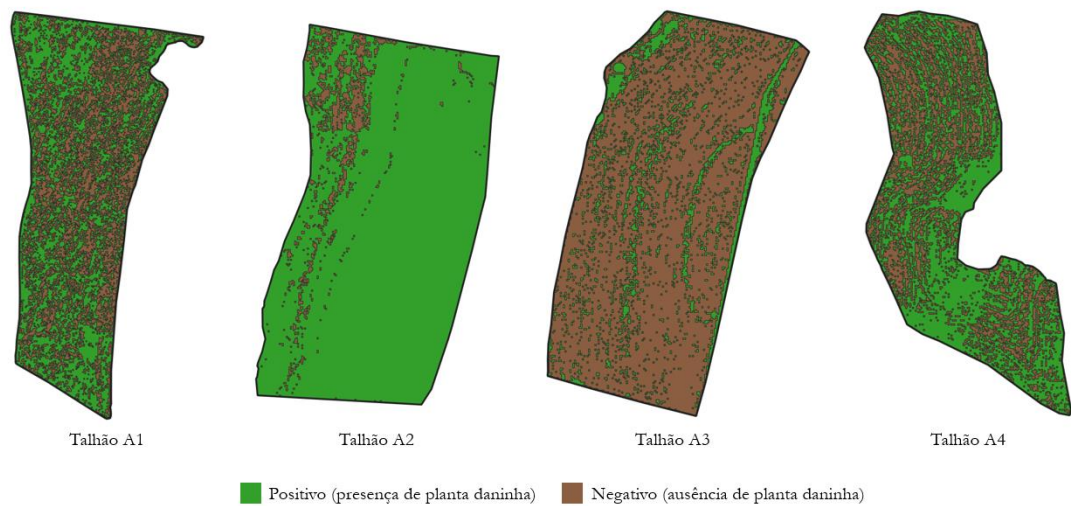


Figura 11. Mapas para aplicação localizada de herbicidas gerados por algoritmo classificador.

4.1. Matriz de confusão

A matriz de confusão foi usada para avaliar o desempenho do algoritmo classificador, gerando um relatório da performance do algoritmo em relação aos dois grupos de repostas possíveis, presença ou ausência de plantas daninhas, conforme o trabalho de Ahmad et al. (2021), em que a matriz de confusão forneceu um relatório detalhado do desempenho dos algoritmos avaliados para identificação de plantas daninhas em imagens RGB no sistema de produção de milho e soja no meio-oeste dos Estados Unidos. A matriz mostrou o número de classificações corretas ou incorretas para a presença ou a ausência de planta daninha, fornecendo os valores de VP, VN, FP e FN, necessários para o cálculo dos indicadores de desempenho dos modelos preditores avaliados.

Na Tabela 4 é possível observar como o algoritmo classificador se comportou diante das classificações feitas, permitindo a análise da quantidade de acertos e erros para cada valor da variável resposta realizada.

Tabela 4. Desempenho do algoritmo classificador utilizando dados obtidos com a matriz de confusão em cada tratamento.

Tratamento	VP	VN	FP	FN
T1 - PDP	43	37	23	17
T2 - PDM	51	42	18	9
T3 - PDG	57	32	28	3

PDP: Plantas daninhas pequenas ($\text{área} \leq 400 \text{ cm}^2$)

PDM: Plantas daninhas médias ($400 \text{ cm}^2 > \text{área} \leq 900 \text{ cm}^2$)

PDG: Plantas daninhas grandes ($> 900 \text{ cm}^2 \text{ área} \leq 1600 \text{ cm}^2$)

Analisando o desempenho do algoritmo para o tratamento 1, que considera as plantas daninhas identificadas com área projetada no solo menor ou igual 400 cm^2 , nota-se que a quantidade de VP, VN, FP e FN foi de 43, 37, 23 e 17, respectivamente. Enquanto, que no tratamento 2, que leva em consideração as plantas com área projetada em solo maiores que 400 cm^2 e menores ou iguais que 900 cm^2 , o algoritmo produziu 51, 42, 18 e 9 para VP, VN, FP e FN, respectivamente. Por fim, no tratamento 3, que contém plantas com área projetada no solo maiores que 900 cm^2 , o desempenho do algoritmo gerou 57, 32, 28 e 3 para VP, VN, FP e FN, respectivamente. Os resultados mostram que quanto maior a área da planta maior é o valor de VP e menor é o valor de FN.

Valente et al. (2019), utilizaram imagens aéreas obtidas com uma câmera RGB acoplada em um ARP que sobrevoou a altura de 10 metros acima do nível do solo para geração de ortomosaico com GSD de $0,6 \text{ cm/pixel}$ e avaliaram o desempenho de um modelo de rede neural na detecção de plantas daninhas em pastagens utilizando a matriz de confusão. Os valores encontrados de VP, VN, FP e FN foram 188, 208, 17 e 18, respectivamente, para um total de 431 amostras.

No contexto de pulverização para o controle de plantas daninhas e sabendo que atualmente muitos agricultores realizam a pulverização em área total, o VP e o FN se tornam mais relevantes, visto que o VP mensura a capacidade do algoritmo em identificar corretamente a presença da planta daninha em campo, permitindo a pulverização localizada, enquanto o FN mensura a insuficiência do algoritmo, visto que o algoritmo não foi capaz de identificar a presença das plantas daninhas localizadas em determinados pontos, portanto nesses locais de FN não será pulverizado, podendo diminuir a produtividade e qualidade do produto cultivado, elevar os custos produtivos, gerar resistência nas plantas daninhas não controladas e até inviabilizar a colheita. O VN e o FP, neste contexto, mensuram a oportunidade em reduzir a quantidade de agrotóxico utilizado nas pulverizações, visto que o VN mensura a capacidade do algoritmo em localizar as ausências de plantas daninhas no campo e o FP mensura o erro do algoritmo em prever presença em locais de ausência, sendo que nestes locais de FP será pulverizado sem necessidade, o que já ocorre em pulverizações em área total.

4.2. Indicadores de desempenho

Os indicadores de desempenho foram utilizados como ferramenta de gestão para avaliar a performance do algoritmo na geração dos mapas de aplicação localizada de herbicidas. Eles permitiram quantificar e identificar uma tendência, condensando as informações em um índice numérico, a partir dos valores VP, VN, FP e FN obtidos com a matriz de confusão.

4.2.1. Precisão

Utilizando os dados de VP e FP, obtidos com a matriz de confusão, foi possível calcular os valores de precisão para cada um dos tratamentos (Tabela 5), e avaliar a capacidade do algoritmo de prever a presença de plantas daninhas, considerando a taxa produzida de FP.

O tratamento 2 (T2 – PDM) obteve a maior média de precisão, atingindo o valor de 0,7788. Enquanto o tratamento 1 (T1 – PDP) apresentou uma média de 0,7352 de precisão e, o tratamento 3 (T3 – PDG) obteve a menor média de precisão, registrando o valor 0,7117.

Um valor alto de precisão indica que o algoritmo foi capaz de identificar as presenças de plantas daninhas, com poucos falsos positivos, sendo que quando a precisão for 1, significa que o algoritmo não produziu falsos positivos. A menor precisão amostral obtida foi de 0,5200 no tratamento 3.

Tabela 5. Precisão do algoritmo classificador em cada tratamento.

Tratamento	Precisão		
	Média	Mínimo	Máximo
T1 - PDP	0,7352	0,5385	1,0000
T2 - PDM	0,7788	0,6000	1,0000
T3 - PDG	0,7117	0,5200	1,0000

PDP: Plantas daninhas pequenas (área ≤ 400 cm²)

PDM: Plantas daninhas médias (400 cm² > área ≤ 900 cm²)

PDG: Plantas daninhas grandes (> 900 cm² área ≤ 1600 cm²)

No trabalho de Reedha et al. (2022), utilizando uma câmera RGB de 36 MP montada em um ARP, com altura de voo de até 30 metros capturaram imagens em áreas agrícolas cultivadas com beterrabas, salsas e espinafres que totalizaram quatro hectares na região do Centro-Vale do Loire, localizada na França. No conjunto de dados coletados, cada imagem foi classificada manualmente em plantas daninhas, beterrabas, salsa e espinafre, compondo os dados da verdade de campo e foi usado a matriz de confusão para avaliar a melhor arquitetura de algoritmos classificadores. Os algoritmos avaliados obtiveram precisões médias acima de 0,98 na identificação de plantas daninhas. No entanto, no trabalho de Islam et al. (2021), avaliando três algoritmos classificadores na detecção de plantas daninhas em um campo de pimenta australiano usando imagens aéreas obtidas por uma câmera RGB de 12,4 MP acoplada em um ARP para geração de ortomosaicos, em que, uma pequena seção da imagem foi rotulada e classificada como plantas daninhas, plantações e solo descoberto para treinamento dos algoritmos de aprendizado de máquina, obtiveram 0,62 de precisão para um dos algoritmos avaliados, sustentando os resultados obtidos neste trabalho.

As precisões obtidas, em comparação com outros trabalhos, mostram que existe uma oportunidade de melhoria no algoritmo, que se alcançada proporcionará redução na quantidade de agrotóxico utilizado, consequentemente podendo reduzir os custos e o impacto ambiental nas pulverizações de herbicidas.

4.2.1. Revocação

Utilizando os dados de VP e FN, obtidos com a matriz de confusão, foi possível calcular os valores de revocação para cada um dos tratamentos (Tabela 6), e avaliar a capacidade do algoritmo de prever a presença de plantas daninhas, considerando a taxa produzida de FN.

Tabela 6. Revocação do algoritmo classificador em cada tratamento.

Tratamento	Revocação		
	Média	Mínimo	Máximo
T1 - PDP	0,7167	0,2667	0,9333
T2 - PDM	0,8500	0,6000	1,0000
T3 - PDG	0,9500	0,8667	1,0000

PDP: Plantas daninhas pequenas ($\text{área} \leq 400 \text{ cm}^2$)

PDM: Plantas daninhas médias ($400 \text{ cm}^2 > \text{área} \leq 900 \text{ cm}^2$)

PDG: Plantas daninhas grandes ($> 900 \text{ cm}^2 \text{ área} \leq 1600 \text{ cm}^2$)

O tratamento 3 (T3 – PDG) obteve a maior média de revocação, atingindo o valor de 0,9500. Enquanto o tratamento 2 (T2 – PDM) apresentou uma média de 0,8500 e, o tratamento 1 (T1-PDP) obteve a menor média de revocação, registrando o valor de 0,7167.

A revocação é a métrica mais relevante para o objetivo deste trabalho, pois em seu cálculo utiliza-se o VP e FN, sendo que um valor alto de revocação significa que o algoritmo foi capaz de identificar as presenças de plantas daninhas, com pouco falsos negativos, sendo que revocação igual a 1, significa que o algoritmo não produziu falsos negativos. A menor revocação amostral obtida foi de 0,2667 no tratamento 1.

Mattivi et al. (2021), avaliando algoritmos para identificação de plantas daninhas em ortomosaicos com resolução de 1,1 cm/pixel, utilizando imagens RGB capturadas por uma câmera de 21 MP acoplada em ARP, que sobrevoou em uma altura de 35 metros acima do nível do solo, alcançaram valores para revocação entre 0,53 e 0,72. Por outro lado, Valente et al. (2019), utilizando ortomosaicos com resolução de 0,6 cm/pixel, utilizando uma câmera RGB de 12 MP acoplada em um ARP, que sobrevoou na altura de 10 metros acima do nível do solo, obtiveram 0,91 de revocação na avaliação do desempenho de um algoritmo para identificação de plantas daninhas, corroborando os resultados obtidos neste trabalho, e sustentando que quanto maior a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes na área, melhor o desempenho do algoritmo avaliado.

4.2.2. Acurácia

Utilizando os dados de VP, VN, FP e FN, obtidos com a matriz de confusão, foi possível calcular os valores de acurácia para cada um dos tratamentos (Tabela 7) e avaliar a proporção entre o número de acertos do algoritmo, presença e ausência de planta daninhas, e o número total de amostras.

Tabela 7. Acurácia do algoritmo classificador em cada tratamento.

Tratamento	Acurácia		
	Média	Mínimo	Máximo
T1 - PDP	0,6667	0,5667	0,8667
T2 - PDM	0,7750	0,6333	0,9000
T3 - PDG	0,7417	0,5333	0,9667

PDP: Plantas daninhas pequenas (área $\leq 400 \text{ cm}^2$)

PDM: Plantas daninhas médias ($400 \text{ cm}^2 > \text{área} \leq 900 \text{ cm}^2$)

PDG: Plantas daninhas grandes ($> 900 \text{ cm}^2 \text{ área} \leq 1600 \text{ cm}^2$)

O tratamento 2 (T2 – PDM) obteve a maior média de acurácia, atingindo o valor de 0,7750. Enquanto o tratamento 3 (T3 – PDG) apresentou uma média de 0,7417 de acurácia e, o tratamento 1 (T1-PDP) obteve a menor média de acurácia, registrando o valor de 0,6667.

Durante a análise comparativa dos resultados, observou-se que os modelos avaliados por Ahmad et al. (2021) para a identificação de plantas daninhas apresentaram uma faixa de acurácias entre 0,91 e 0,99. Em contraste, ao examinar o estudo realizado por Islam et al. (2021), constatou-se que os modelos avaliados alcançaram valores de acurácia que variaram de 0,63 a 0,96, corroborando os resultados obtidos no presente trabalho.

No estudo de Reedha et al. (2022), a acurácia não foi utilizada na avaliação dos algoritmos classificadores de plantas daninhas, pois para o seu cálculo é utilizado valores de VNs, ou seja, a capacidade do algoritmo identificar ausência de plantas daninhas na área. Os autores reconhecem que não levar em consideração os valores de VNs podem causar problemas em tarefas de classificação específicas, nas quais os VNs têm um impacto significativo nas predições dos algoritmos, contudo, entendem que não é o caso na identificação de plantas daninhas em áreas agrícolas, visto que é preferível superdetectar³ plantas daninhas do que subdetectá-las. Este fato corrobora com os resultados obtidos neste trabalho, sustentando que a revocação é a métrica mais relevante na avaliação de mapas para aplicação localizada de herbicidas, por utilizar VP e FN em sua equação, diferente da acurácia que calcula a proporção entre o número de amostras classificadas corretamente, considerando VP e VN, e o número total de amostras, considerando os erros gerados por FP e FN.

Se observarmos os valores de acurácia de maneira isolada, pode-se afirmar que o algoritmo performou melhor no tratamento 2 do que no tratamento 3, sendo que o tratamento 3 considerou plantas maiores. Todavia esse resultado ocorreu devido a influência da maior quantidade de FP incidido no tratamento 3. Contudo, no contexto de pulverização localizada de herbicida, em que é preferível superdetectar plantas daninhas do que subdetectá-las, não é plausível considerar que o algoritmo performou melhor no tratamento 2, sustentando que quanto maior a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes na área, melhor o desempenho do algoritmo avaliado.

4.2.3. F-score

Utilizando os dados de VP, FP e FN, obtidos com a matriz de confusão, foi possível calcular os valores de *F-score* para cada um dos tratamentos (Tabela 8), e avaliar a média harmônica ponderada da precisão e revocação.

³ Superdetectar significa detectar uma quantidade maior do que a real existente de um dado elemento, gerando falso positivo.

O tratamento 3 (T3 – PDG) obteve a maior média de *F-score*, atingindo o valor de 0,8011. Enquanto o tratamento 2 (T2 – PDM) apresentou uma média de 0,7889 para o *F-score* e, o tratamento 1 (T1-PDP) obteve a menor média de *F-score*, registrando o valor de 0,6565.

Um valor alto de *F-score* significa que o algoritmo teve a capacidade de identificar corretamente as plantas daninhas e minimizar os falsos positivos e falsos negativos, sendo que *F-score* igual a 1, significa que o algoritmo não produziu falsos positivos e falsos negativos. O menor *F-score* amostral obtido foi de 0,4211 no tratamento 1.

Reedha et al. (2022) investigando a influência do número de imagens de treinamento no desempenho dos modelos avaliados, constataram por meio da validação cruzada um *F-score* médio acima de 0,98. Os resultados indicaram uma diminuição mínima no desempenho dos modelos à medida que o número de imagens de treinamento é reduzido, sugerindo que mesmo com uma quantidade menor de dados de treinamento, os modelos mantêm um desempenho consistente e robusto, indicando a possibilidade de otimizar o uso de recursos de treinamento, sem comprometer significativamente a eficácia do modelo.

Tabela 8. *F-score* do algoritmo classificador em cada tratamento.

Tratamento	F-score		
	Média	Mínimo	Máximo
T1 - PDP	0,6565	0,4211	0,8750
T2 - PDM	0,7889	0,6857	0,9091
T3 - PDG	0,8011	0,6500	0,9655

PDP: Plantas daninhas pequenas (área ≤ 400 cm²)

PDM: Plantas daninhas médias (400 cm² > área ≤ 900 cm²)

PDG: Plantas daninhas grandes (> 900 cm² área ≤ 1600 cm²)

Ao analisar e comparar os resultados para a identificação de plantas daninhas, foi verificado que os modelos avaliados por Ahmad et al. (2021), apresentaram um intervalo de *F-score* entre 0,81 e 0,99, e média de 0,93. Além disso constatou-se que os modelos treinados nas estruturas de aprendizado profundo tiveram um desempenho consistentemente superior em termos *F-score* e tempo de treinamento, sugerindo que o uso de abordagens baseadas em aprendizado profundo pode ser usado na identificação de plantas daninhas, proporcionando um equilíbrio entre desempenho e tempo no processo de treinamento dos modelos.

Os resultados de *F-score* obtidos neste trabalho, demonstram que quanto maior a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes na área, melhor será o desempenho do algoritmo avaliado. Contudo, ao comparar com os resultados obtidos em outros trabalhos semelhantes, observa-se que existe uma oportunidade de melhoria no desempenho do algoritmo, principalmente para identificar plantas daninhas com área projetada em solo menor que 400 cm².

4.2.4. MCC

Utilizando os dados de VP, VN, FP e FN, obtidos com a matriz de confusão, foi possível calcular os valores de MCC para cada um dos tratamentos (Tabela 9), e avaliar o desempenho do algoritmo, considerando as quatro categorias da matriz de confusão (VP, VN, FP e FN) e o peso que cada uma delas possuem no conjunto de dados.

O tratamento 2 (T2 – PDM) obteve a maior média de MCC, atingindo o valor de 0,5893. Enquanto o tratamento 3 (T3 – PDG) apresentou uma média de 0,5310 para o MCC e, o tratamento 1 (T1-PDP) obteve a menor média de MCC, registrando o valor de 0,3840.

Mattivi et al. (2021), utilizaram um conjunto de dados de referência desbalanceado de presença e ausência de plantas daninhas, identificadas por meio da interpretação visual de ortomosaico com resolução de 1,1 cm/pixel, construído a partir de imagens RGB, obtidas por uma câmera de 21 MP acoplada em um ARP, que sobrevoou a altura de 35 metros. Os dados continham 90% de ausência de plantas daninhas e 10% com presença, consequentemente, os autores entenderam que as métricas usuais calculadas a partir da matriz de confusão, podem ser excessivamente otimistas, portanto, incluíram o MCC na avaliação dos algoritmos para identificação de plantas daninhas, obtendo valores de MCC entre 0,67 e 0,74.

Tabela 9. MCC do algoritmo classificador em cada tratamento.

Tratamento	MCC		
	Média	Mínimo	Máximo
T1 - PDP	0,3840	0,1961	0,7399
T2 - PDM	0,5893	0,2828	0,8165
T3 - PDG	0,5310	0,0894	0,9354

PDP: Plantas daninhas pequenas (área $\leq 400 \text{ cm}^2$)

PDM: Plantas daninhas médias ($400 \text{ cm}^2 > \text{área} \leq 900 \text{ cm}^2$)

PDG: Plantas daninhas grandes ($> 900 \text{ cm}^2 \text{ área} \leq 1600 \text{ cm}^2$)

Um valor alto de MCC significa que o algoritmo teve a capacidade de identificar corretamente as presenças e as ausências de plantas daninhas, minimizando os falsos positivos e falsos negativos, sendo que MCC igual a 1, significa que o algoritmo não produziu falsos positivos e falsos negativos. O menor MCC amostral obtido foi de 0,0894 no tratamento 3.

Neste trabalho, em que os dados estão balanceados, ou seja, os dados de referência (mapa verdade de campo) possuem 50% de ausência e 50% de presença de plantas daninhas, o MCC não se mostrou o indicador de desempenho mais relevante para avaliação do algoritmo classificador. Além disso, no contexto de pulverização localizada de herbicidas, conforme visto em Reedha et al. (2022), é preferível superdetectar plantas daninhas do que subdetectá-las, demonstrando que o FP deveria ter menos peso na avaliação do algoritmo do que o FN, visto que a ocorrência de FP implica em pulverizar um local em que não há a presença de planta daninha, situação que já ocorre em pulverização em área total, enquanto que a ocorrência de FN implica em não pulverizar um local em que há a presença de planta daninha, o que é mais relevante no cenário agrícola. Contudo, o cálculo do MCC atribui pesos iguais ao FP e FN e prejudicou os resultados obtidos na avaliação do algoritmo classificador deste estudo.

4.2.5. Correlação linear de Pearson

Ao analisar a correlação linear de Pearson entre os mapas da verdade de campo e aplicação localizada de herbicidas gerados por algoritmo classificador, observou-se que houve correlação positiva significativa em todos os três tratamentos, com valores de coeficientes de correlação variando de 0,335 a 0,556, conforme Tabela 10. Sendo que o tratamento T1 – PDP apresentou média correlação, enquanto os tratamentos T2 – PDM e T3 – PDG apresentaram correlação grande, conforme proposto por Cohen (1988).

Tabela 10. Coeficientes de correlação linear de Pearson entre os mapas da verdade de campo e aplicação localizada de herbicidas gerados por algoritmo classificador.

Tratamento	Correlação	IC de 95% para ρ
T1 – PDP	0,335***	(0,166; 0,485)***
T2 – PDM	0,556***	(0,419; 0,669)***
T3 – PDG	0,532***	(0,390; 0,649)***

***Significativo a 0,001; **Significativo a 0,01; *Significativo a 0,05; ns = Não significativo

PDP: Plantas daninhas pequenas (área $\leq 400 \text{ cm}^2$)

PDM: Plantas daninhas médias ($400 \text{ cm}^2 > \text{área} \leq 900 \text{ cm}^2$)

PDG: Plantas daninhas grandes ($> 900 \text{ cm}^2 \text{ área} \leq 1600 \text{ cm}^2$)

Foram calculados os intervalos de confiança de 95% para cada tratamento, indicando a margem de erro associada à estimativa da correlação e permitindo inferir com um nível de confiança de 95% que a verdadeira correlação está contida dentro do intervalo. Quanto menor o intervalo, mais precisa é a estimativa da correlação. Portanto, é possível verificar que o tratamento T2 – PDM apresentou o intervalo de confiança mais estreito (0,419; 0,669), indicando que a estimativa da correlação é mais precisa e a incerteza associada a ela é menor. Já o intervalo de confiança mais amplo foi encontrado para o tratamento T1 – PDP (0,166; 0,485), indicando que a estimativa da correlação é menos precisa e a incerteza associada a ela é maior.

Os resultados obtidos da pesquisa de Burgos-Artizzu et al. (2009) para estimar a cobertura de plantas daninhas em campos de cultivo, utilizando o processamento de imagens digitais, capturadas em solo com resolução de 0,006 cm/pixel adquiridas de diferentes áreas e sob diferentes condições não controladas de luminosidade e tamanhos de plantas daninhas, obtiveram coeficientes de correlação de Pearson que variaram de 0,587 a 0,797, considerados valores de grande magnitude (COHEN, 1988). Comparando estes resultados com os obtidos neste trabalho, nota-se que para os tratamentos T2 – PDM e T3 – PDG, os valores de coeficientes de correlação de Pearson obtidos são valores considerados médios e grandes, respectivamente, sendo que os valores nominais obtidos neste trabalho são menores. O principal motivo dessa diferença é a resolução das imagens utilizadas neste trabalho (2,5 cm/pixel), sustentando que quanto maior a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes na área, melhor o desempenho do algoritmo avaliado.

No presente estudo, os indicadores de desempenho precisão, revocação, acurácia, *F-score*, MCC e correlação linear de Pearson foram utilizados para avaliação do algoritmo classificador. Contudo, no contexto agrícola, em que a pulverização de herbicidas em área total é praticada larga escala, a revocação se mostrou o indicador mais relevante, visto que considera a quantidade produzida de VP e FN, ou seja, capacidade de identificar (VP) e de não identificar (FN) as plantas daninhas no campo. Os valores de revocação mostraram que a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes nas áreas afetam o desempenho do algoritmo, visto que quanto maior a resolução ou o tamanho das plantas daninhas, maior o valor da revocação. Este fato pode ser explicado pelo motivo que plantas maiores ou resolução de imagens melhores possibilitam a distinção mais contundente entre plantas daninhas e demais elementos presentes na área, como solo descoberto ou palhada.

5. CONCLUSÕES

Para avaliar o desempenho do algoritmo classificador de presença ou ausência de plantas daninhas na geração de mapas para aplicação localizada de herbicidas, foi analisado os acertos e erros do algoritmo obtidos em diferentes tamanhos de plantas (pequenas, médias e grandes), utilizando gabaritos com áreas de 400 cm², 900 cm² e 1600 cm² para auxiliar na classificação.

A matriz de confusão permitiu avaliar o desempenho do algoritmo, calculando os indicadores de desempenho precisão, revocação, acurácia, *F-score*, MCC e correlação linear de Pearson. Os resultados mostraram que à medida que as plantas aumentam de tamanho, maiores são os valores de verdadeiros positivos (VPs) e menores são os valores de falsos negativos (FNs).

Para dados balanceados e no contexto de pulverização localizada de herbicidas, o indicador que se mostrou mais relevante foi a revocação, por considerar as predições de presenças corretas (VPs) e as predições de ausências incorretas (FNs) geradas pelo algoritmo avaliado. Os resultados mostraram que o algoritmo apresentou melhor desempenho para plantas daninhas grandes, com área projetada em solo maiores que 900 cm², o que pode ser justificado pelo fato de que plantas maiores possuem características mais evidentes de serem identificadas em ortomosaicos com GSD de 2,5 cm/pixel.

A quantidade gerada de falsos positivos (FPs), penalizou principalmente os valores de MCC, que se mostrou um indicador muito sensível as variações desses erros, portanto não indicado para dados balanceados no contexto de pulverização localizada de herbicidas, em que é preferível superdetectar as plantas daninhas do que subdetectá-las.

Em relação à precisão e a acurácia, pode-se observar que os valores médios, independentemente do tamanho de plantas daninhas estão dentro da faixa encontrada em trabalhos semelhantes, demonstrando o cuidado que é necessário ao analisar esses indicadores isoladamente.

Por sua vez, o *F-score*, que é uma medida de equilíbrio entre precisão e revocação, apresentou valores mais altos para as plantas daninhas médias e grandes em comparação com as plantas pequenas, indicando que o algoritmo é mais eficiente na detecção de plantas maiores que 400 cm² de área projetada em solo.

A correlação linear de Pearson, que é uma medida de correlação entre os resultados previstos e os resultados reais, apresentou correlações de magnitude média e grande, sendo que as maiores correlações entre o mapa da verdade de campo e mapa gerado pelo algoritmo classificador foram obtidas com plantas daninhas médias e grandes, com áreas projetadas em solo maiores que 400 cm², sustentando que as plantas maiores possuem características mais notórias para serem localizadas por algoritmos classificadores.

Por fim, conclui-se que os resultados obtidos sugerem que o uso de algoritmos de inteligência artificial para a classificação de imagens aéreas é uma técnica promissora para a aplicação localizada de herbicidas em plantas daninhas. No entanto, são necessários ajustes e aprimoramentos no algoritmo avaliado para melhorar sua precisão e confiabilidade, principalmente para plantas daninhas com áreas projetadas em solo menores que 400 cm². Futuras pesquisas podem avaliar o desempenho de algoritmos para identificação de diferentes tamanhos de plantas daninhas, utilizando ortomosaicos com diferentes resoluções.

REFERÊNCIAS

- AHMAD, A.; SARASWAT, D.; AGGARWAL, V.; ETIENNE, A.; HANCOCK, B. Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems. **Computers and Electronics in Agriculture**, v. 184, p. 106081, 2021.
- ALTHOFF, D.; BAZAME, H. C.; FILGUEIRAS, R.; DIAS, S. H. B. Heuristic methods applied in reference evapotranspiration modeling. **Ciência e Agrotecnologia**, v. 42, n. 3, p. 314–324, 2018.
- ANDÚJAR, D.; ESCOLÀ, A.; DORADO, J.; FERNÁNDEZ-QUINTANILLA, C. Weed discrimination using ultrasonic sensors. **Weed Research**, v. 51, n. 6, p. 543–547, 2011.
- BALASTREIRE, L. A.; BAIIO, F. H. R. Avaliação de uma metodologia prática para o mapeamento de plantas daninhas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 5, n. 2, p. 349–352, 2001.
- BALDI, P.; BRUNAK, S.; CHAUVIN, Y.; ANDERSEN, C. A. F.; NIELSEN, H. Assessing the accuracy of prediction algorithms for classification: an overview. **Bioinformatics**, v. 16, n. 5, p. 412–424, 2000.
- BARBEDO, J. G. A. Detecting and Classifying Pests in Crops Using Proximal Images and Machine Learning: A Review. **AI**, v. 1, n. 2, p. 312–328, 2020.
- BORGES, L. C.; NASCIMENTO, A. dos R.; MORGADO, C. M. A. Agricultura de precisão: ferramenta de gestão na rentabilidade e produtividade de grãos. **Scientific Electronic Archives**, v. 15, n. 3, 2022.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHÉ, A.; PAJARES, G.; FERNÁNDEZ-QUINTANILLA, C. Improving weed pressure assessment using digital images from an experience-based reasoning approach. **Computers and Electronics in Agriculture**, v. 65, n. 2, p. 176–185, 2009.
- CASTALDI, F.; PELOSI, F.; PASCUCCI, S.; CASA, R. Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize. **Precision Agriculture**, v. 18, n. 1, p. 76–94, 2017.
- CHENG, G.; HAN, J.; LU, X. Remote Sensing Image Scene Classification: Benchmark and State of the Art. **Proceedings of the IEEE**, v. 105, n. 10, p. 1865–1883, 2017.
- CHICCO, D.; JURMAN, G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC Genomics**, v. 21, n. 1, p. 6, 2020.
- CHIU, M. T.; XU, X.; WEI, Y.; HUANG, Z.; SCHWING, A. G.; BRUNNER, R.; KHACHATRIAN, H.; KARAPETYAN, H.; DOZIER, I.; ROSE, G.; OTHERS. Agriculture-vision: A large aerial image database for agricultural pattern analysis. **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**, p. 2828–2838, 2020.

CHOI, S.-S.; CHA, S.-H.; TAPPERT, C. C.; OTHERS. A survey of binary similarity and distance measures. **Journal of systemics, cybernetics and informatics**, v. 8, n. 1, p. 43–48, 2010.

CHRISTOFFOLETI, P. J.; LÓPES OVEJERO, R. F. Resistência de plantas daninhas a herbicidas: definições, bases e situação no Brasil e no mundo. *Em: Aspectos de resistência de Plantas Daninhas a Herbicidas*. Piracicaba, SP: Associação Brasileira de Ação à Resistência de Plantas Daninhas aos Herbicidas - (HRAC-BR), 2008.

CHRISTOFFOLETI, P. J.; VICTORIA FILHO, R.; SILVA, C. B. da. Resistência de plantas daninhas aos herbicidas. **Planta Daninha**, v. 12, n. 1, p. 13–20, 1994.

CNA - CONFEDERAÇÃO NACIONAL DA AGRICULTURA E PECUÁRIA; CEPEA - CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA. **PIB do agronegócio brasileiro**. Disponível em: <www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>. Acesso em: 14 jan. 2023.

COHEN, J. Statistical power analysis for the behavioural sciences. Hillsdale, New Jersey: L. **Lea**, v. 56, p. 102, 1988.

COLBACH, N.; COLAS, F.; CORDEAU, S.; MAILLOT, T.; QUEYREL, W.; VILLERD, J.; MOREAU, D. The FLORSYS crop-weed canopy model, a tool to investigate and promote agroecological weed management. **Field Crops Research**, v. 261, 2021.

CONCENÇO, G.; TOMAZI, M.; CORREIA, I. V. T.; SANTOS, S. A.; GALON, L. Phytosociological surveys: tools for weed science? **Planta Daninha**, v. 31, n. 2, p. 469–482, jun. 2013.

DÉLYE, C.; JASIENIUK, M.; LE CORRE, V. Deciphering the evolution of herbicide resistance in weeds. **Trends in Genetics**, v. 29, n. 11, p. 649–658, 2013.

DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. **The Journal of Machine learning research**, v. 7, p. 1–30, 2006.

DOS SANTOS, L. T.; DA SILVA JÚNIOR, D. F.; DA SILVA, V. L. B.; DE ANDRADE, G. M.; DA SILVA, J. M. P.; LIRA, T. A. M. MANEJO AGROECOLÓGICO DE PRAGAS: DESENVOLVIMENTO SUSTENTÁVEL NA AGRICULTURA: AGROECOLOGICAL PEST MANAGEMENT: SUSTAINABLE DEVELOPMENT IN AGRICULTURE. **Revista de Ciências da Saúde Nova Esperança**, v. 20, n. 3, p. 199–205, 2022.

ESCOLA, J. P. L.; GUIDO, R. C.; DA SILVA, I. N.; CARDOSO, A. M.; MACCAGNAN, D. H. B.; DEZOTTI, A. K. Automated acoustic detection of a cicadid pest in coffee plantations. **Computers and Electronics in Agriculture**, v. 169, p. 105215, 2020.

FAO. Pesticides use, pesticides trade and pesticides indicators Global, regional and country trends, 1990–2020. **FAOSTAT Analytical Briefs**, v. 46, 2022.

FAO; WHO. **Preventing suicide: a resource for pesticide registrars and regulators**, 2019. Disponível em: <<https://www.who.int/publications/i/item/9789241516389>>. Acesso em: 21 jan. 2023.

FAVRETO, R.; MEDEIROS, R. B. de. Bancos de sementes do solo em áreas agrícolas: potencialidades de uso e desafios para o manejo. **Pesquisa Agropecuária Gaúcha**, v. 10, n. 1/2, p. 78–89, 2004.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.

FERREIRA, E. A.; PROCÓPIO, S. O.; GALON, L.; FRANCA, A. C.; CONCENÇO, G.; SILVA, A. A.; ASPIAZU, I.; SILVA, A. F.; TIRONI, S. P.; ROCHA, P. R. R. Manejo de plantas daninhas em cana-crua. **Planta Daninha**, v. 28, n. 4, p. 915–925, 2010.

FRASCONI, C.; RAFFAELLI, M.; EMMI, L.; FONTANELLI, M.; MARTELLONI, L.; PERUZZI, A. An automatic machine able to perform variable rate application of flame weeding: Design and assembly. **Chemical Engineering Transactions**, v. 58, p. 301–306, 2017.

GAO, J.; NUYTTENS, D.; LOOTENS, P.; HE, Y.; PIETERS, J. G. Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. **Biosystems Engineering**, v. 170, p. 39–50, 2018.

GEIGER, F.; BENGTSSON, J.; BERENDSE, F.; WEISSER, W. W.; EMMERSON, M.; MORALES, M. B.; CERYNGIER, P.; LIIRA, J.; TSCHARNTKE, T.; WINQVIST, C.; EGGERS, S.; BOMMARCO, R.; PÄRT, T.; BRETAGNOLLE, V.; PLANTEGENEST, M.; CLEMENT, L. W.; DENNIS, C.; PALMER, C.; OÑATE, J. J.; GUERRERO, I.; HAWRO, V.; AAVIK, T.; THIES, C.; FLOHRE, A.; HÄNKE, S.; FISCHER, C.; GOEDHART, P. W.; INCHAUSTI, P. Persistent negative effects of pesticides on biodiversity and biological control potential on European farmland. **Basic and Applied Ecology**, v. 11, n. 2, p. 97–105, 2010.

GERHARDS, R.; WYSE-PESTER, D. Y.; MORTENSEN, D.; JOHNSON, G. A. Characterizing spatial stability of weed populations using interpolated maps. **Weed Science**, v. 45, n. 1, p. 108–119, 1997.

GORODKIN, J. Comparing two K-category assignments by a K-category correlation coefficient. **Computational Biology and Chemistry**, v. 28, n. 5–6, p. 367–374, 2004.

GRUNDY, A. C.; MEAD, A.; BURSTON, S.; OVERS, T. Seed production of *Chenopodium album* in competition with field vegetables. **Weed Research**, v. 44, n. 4, p. 271–281, 2004.

HEINE-FUSTER, I.; ARÁNGUIZ-ACUÑA, A.; RAMOS-JILIBERTO, R. Pesticide increases transgenerational cost of inducible defenses in a freshwater rotifer. **Hydrobiologia**, v. 799, n. 1, p. 249–260, 2017.

IBGE - PPP - Serviço online para pós-processamento de dados GNSS, 2022. Disponível em: <<https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16334-servico-online-para-pos-processamento-de-dados-gnss-ibge-ppp.html?=&t=processar-os-dados>>. Acesso em: 3 out. 2022.

IMEA - INSTITUTO MATO-GROSSENSE DE ECONOMIA AGROPECUÁRIA. **Relatório de mercado**, 2023. Disponível em: <<https://www.imea.com.br/imea-site/relatorios-mercado>>. Acesso em: 10 fev. 2023.

ISLAM, N.; RASHID, M. M.; WIBOWO, S.; XU, C.-Y.; MORSHED, A.; WASIMI, S. A.; MOORE, S.; RAHMAN, S. M. Early Weed Detection Using Image Processing and Machine Learning Techniques in an Australian Chilli Farm. **Agriculture**, v. 11, n. 5, p. 387, 2021.

JOHANNES, A.; PICON, A.; ALVAREZ-GILA, A.; ECHAZARRA, J.; RODRIGUEZ-VAAMONDE, S.; NAVAJAS, A. D.; ORTIZ-BARREDO, A. Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. **Computers and Electronics in Agriculture**, v. 138, p. 200–209, 2017.

JOHNSON, G. A.; MORTENSEN, D. A.; MARTIN, A. R. A simulation of herbicide use based on weed spatial distribution. **Weed Research**, v. 35, n. 3, p. 197–205, 1995.

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

KODALI, R. K.; RAWAT, N.; BOPPANA, L. WSN sensors for precision agriculture. **2014 IEEE REGION 10 SYMPOSIUM**, p. 651–656, 2014.

KÖPPEN, W. P. **Grundriss der klimakunde**. [s.l.] W. de Gruyter, 1931.

LAMB, D. W.; BROWN, R. B. PA—Precision Agriculture. **Journal of Agricultural Engineering Research**, v. 78, n. 2, p. 117–125, 2001.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015.

LEFÈVRE, A.; PERRIN, B.; LESUR-DUMOULIN, C.; SALEMBIER, C.; NAVARRETE, M. Challenges of complying with both food value chain specifications and agroecology principles in vegetable crop protection. **Agricultural Systems**, v. 185, 2020.

LELONG, C.; BURGER, P.; JUBELIN, G.; ROUX, B.; LABBÉ, S.; BARET, F. Assessment of Unmanned Aerial Vehicles Imagery for Quantitative Monitoring of Wheat Crop in Small Plots. **Sensors**, v. 8, n. 5, p. 3557–3585, 2008.

LIMA, A. F.; SILVA, E. G. de A.; IWATA, B. de F. Agriculturas e agricultura familiar no Brasil: uma revisão de literatura. **Retratos de Assentamentos**, v. 22, n. 1, p. 50–68, 2019.

LIU, B.; BRUCH, R. Weed Detection for Selective Spraying: a Review. **Current Robotics Reports**, v. 1, n. 1, p. 19–26, 2020.

LIU, Y.; CHENG, J.; YAN, C.; WU, X.; CHEN, F. Research on the Matthews correlation coefficients metrics of personalized recommendation algorithm evaluation. **International Journal of Hybrid Information Technology**, v. 8, n. 1, p. 163–172, 2015.

LONGCHAMPS, L.; PANNETON, B.; SIMARD, M.-J.; LEROUX, G. D. Could Weed Sensing in Corn Interrows Result in Efficient Weed Control? **Weed Technology**, v. 26, n. 4, p. 649–656, 2012.

LOPES, C. C.; FONTES, L. de O.; LAZZARINI, L. E. S.; FREITAS, F. C. L. de; COSTA FILHO, J. H. da; SOUSA, E. R. de. Phytosociological survey of weed plants in soybean culture in the Gurguéia Valley. **Scientia Agraria Paranaensis**, v. 20, n. 1, p. 75–80, 2021.

LÓPEZ-GRANADOS, F. Weed detection for site-specific weed management: mapping and real-time approaches. **Weed Research**, v. 51, n. 1, p. 1–11, 2011.

LÓPEZ-GRANADOS, F.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; DE CASTRO, A. I.; MESAS-CARRASCO, Fco.-J.; PEÑA, J.-M. Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds. **Precision Agriculture**, v. 17, n. 2, p. 183–199, 2016.

LÓPEZ-OVEJERO, R. F.; CARVALHO, S. J. P.; NICOLAI, M.; CHRISTOFFOLETI, P. J. Suscetibilidade comparativa a herbicidas pós-emergentes de biótipos de *Digitaria ciliaris* resistente e suscetível aos inibidores da ACCase. **Planta Daninha**, v. 24, n. 4, p. 789–796, 2006.

LU, Y.; YOUNG, S. A survey of public datasets for computer vision tasks in precision agriculture. **Computers and Electronics in Agriculture**, v. 178, p. 105760, 2020.

LUQUE, A.; CARRASCO, A.; MARTÍN, A.; DE LAS HERAS, A. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognition**, v. 91, p. 216–231, 2019.

MA, L.; LIU, Y.; ZHANG, X.; YE, Y.; YIN, G.; JOHNSON, B. A. Deep learning in remote sensing applications: A meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, p. 166–177, 2019.

MAHÉ, I.; CORDEAU, S.; BOHAN, D. A.; DERROUCH, D.; DESSAINT, F.; MILLOT, D.; CHAUVEL, B. Soil seedbank: Old methods for new challenges in agroecology? **Annals of Applied Biology**, v. 178, n. 1, p. 23–38, 2021.

MAJOR, J.; PYOTT, W. T. Buried, viable seeds in two California bunchgrass sites and their bearing on the definition of a flora. **Vegetatio Acta Geobotanica**, v. 13, n. 5, p. 253–282, 1966.

MARAÑÓN, T.; BARTOLOME, J. W. Seed and seedling populations in two contrasted communities: open grassland and oak (*Quercus agrifolia*) understory in California. **Acta Oecologica Plantarum**, v. 10, n. 2, p. 147–158, 1989.

MARTINELLI, R.; ORZARI, I.; FERREIRA, C. S. dos S. **Controle de Plantas Daninhas**. Londrina, PR: Editora e Distribuidora Educacional S.A., 2019. 192 p.

MATTHEWS, B. W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta (BBA) - Protein Structure**, v. 405, n. 2, p. 442–451, 1975.

MATTIVI, P.; PAPPALARDO, S. E.; NIKOLIĆ, N.; MANDOLES, L.; PERSICHETTI, A.; DE MARCHI, M.; MASIN, R. 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.

MAVRIDOU, E.; VROCHIDOU, E.; PAPAKOSTAS, G. A.; PACHIDIS, T.; KABURLASOS, V. G. Machine Vision Systems in Precision Agriculture for Crop Farming. **Journal of Imaging**, v. 5, n. 12, p. 89, 2019.

MEGETO, G. A. S.; SILVA, A. G. da; BULGARELLI, R. F.; BUBLITZ, C. F.; VALENTE, A. C.; COSTA, D. A. G. da. Artificial intelligence applications in the agriculture 4.0. **Revista Ciência Agronômica**, v. 51, n. 5, 2020.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using Deep Learning for Image-Based Plant Disease Detection. **Frontiers in Plant Science**, v. 7, 2016.

MONQUERO, P. A.; CHRISTOFFOLETI, P. J. BANCO DE SEMENTES DE PLANTAS DANINHAS E HERBICIDAS COMO FATOR DE SELEÇÃO. **Bragantia**, v. 64, n. 2, p. 203–209, 2005.

NAULAERTS, S.; DANG, C. C.; BALLESTER, P. J. Precision and recall oncology: combining multiple gene mutations for improved identification of drug-sensitive tumours. **Oncotarget**, v. 8, n. 57, p. 97025–97040, 2017.

NORSWORTHY, J. K.; KORRES, N. E.; BAGAVATHIANNAN, M. v. Weed Seedbank Management: Revisiting How Herbicides Are Evaluated. **Weed Science**, v. 66, n. 4, p. 415–417, 21 jul. 2018.

OERKE, E. C. Crop losses to pests. **Journal of Agricultural Science**, v. 144, n. 1, p. 31–43, 2006.

OLIVEIRA, A. R.; FREITAS, S. P. Levantamento fitossociológico de plantas daninhas em áreas de produção de cana-de-açúcar. **Planta Daninha**, v. 26, n. 1, p. 33–46, 2008.

OLIVEIRA, A. J. de; SILVA, G. F. da; SILVA, G. R. da; SANTOS, A. A. C. dos; CALDEIRA, D. S. A.; VILARINHO, M. K. C.; BARELLI, M. A. A.; OLIVEIRA, T. C. de. POTENCIALIDADES DA UTILIZAÇÃO DE DRONES NA AGRICULTURA DE PRECISÃO / DRONES POTENTIALITY USE IN PRECISION AGRICULTURE. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140–64149, 2020.

OLIVEIRA, M. F. de; BRIGHENTI, A. M.; FONTANETTI, A.; VIEIRA, B. S.; FERREIRA, E. A.; IKEDA, F. S.; ALMEIDA, F. C.; NETO, F. S.; SALGADO, G. C.; CONCENÇO, G.; PERES, G. R. de C.; LIMA, H. R. P.; ASPIAZÚ, I.; GALVÃO, J. C. C.; FONTE, J. R. A.; NECHET, K. de L.; GALON, L.; MORAES, L. F. D. de; OLIVEIRA, M. F.; GIÉPEN, M.; BARRETO, R. W.; OLIVEIRA, S. C. C.; FILHO, S. de A. C.; SANTOS, T. C. G.; KÖPKE, U.; SILVA, M. R. da; MARQUES, T. de S.; KURACHI, S. A. H.; FILHO, A. P.; DANIEL, L. A. **Controle de plantas daninhas: métodos físico, mecânico, cultural, biológico e alelopatia**. Brasília, DF: Embrapa, 2018. 196 p.

ONU. **Transformando Nosso Mundo: A Agenda 2030 para o Desenvolvimento Sustentável**, 2015. Disponível em: <<https://brasil.un.org/sites/default/files/2020-09/agenda2030-pt-br.pdf>>. Acesso em: 21 jan. 2023.

OWEN, M. D. K. Diverse Approaches to Herbicide-Resistant Weed Management. **Weed Science**, v. 64, n. SP1, p. 570–584, 2016.

PEÑA, J.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; DE CASTRO, A.; LÓPEZ-GRANADOS, F. Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. **Sensors**, v. 15, n. 3, p. 5609–5626, 2015.

PETEINATOS, G. G.; WEIS, M.; ANDÚJAR, D.; RUEDA AYALA, V.; GERHARDS, R. Potential use of ground-based sensor technologies for weed detection. **Pest Management Science**, v. 70, n. 2, p. 190–199, 2014.

PINHAS, J.; SOROKER, V.; HETZRONI, A.; MIZRACH, A.; TEICHER, M.; GOLDBERGER, J. Automatic acoustic detection of the red palm weevil. **Computers and Electronics in Agriculture**, v. 63, n. 2, p. 131–139, 2008.

QUEIROZ, D. M. de; COELHO, A. L. de F.; VALENTE, D. S. M.; SCHUELLER, J. K. Sensors Applied to Digital Agriculture: A Review. **Revista Ciência Agronômica**, v. 51, n. 5, 2020.

REEDHA, R.; DERICQUEBOURG, E.; CANALS, R.; HAFIANE, A. Transformer Neural Network for Weed and Crop Classification of High Resolution UAV Images. **Remote Sensing**, v. 14, n. 3, p. 592, 2022.

SAHOO, S.; RUSSO, T. A.; ELLIOTT, J.; FOSTER, I. Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S. **Water Resources Research**, v. 53, n. 5, p. 3878–3895, 2017.

SAMBUICHI, R. H. R. O.; MOURA, I. F. de O.; MATTOS, L. M. de O.; ÁVILA, M. L. de O.; SPINOLA, P. A. C. O.; SILVA, A. P. M. da O. **A política nacional de agroecologia e produção orgânica no Brasil: uma trajetória de luta pelo desenvolvimento rural sustentável**. Brasília: Instituto de Pesquisa Econômica Aplicada (IPEA), 2017. 463 p.

SANTOS, H. G., JACOMINE, P. K. T., ANJOS, L. H. C., OLIVEIRA, V. A., LUMBRERAS, J. F., COELHO, M. R., ALMEIDA, J. A., ARAÚJO FILHO, J. C., OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos**. Brasília: Embrapa, 2018.

SANTOS, W. F.; PROCÓPIO, S. O.; SILVA, A. G.; FERNANDES, M. F.; BARROSO, A. L. L. Weed Phytosociological and Floristic Survey in Agricultural Areas of Southwestern Goiás Region. **Planta Daninha**, v. 34, n. 1, p. 65–80, 2016.

SENSEFLY. eBee X Drone User Manual. 2019.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on Image Data Augmentation for Deep Learning. **Journal of Big Data**, v. 6, n. 1, p. 60, 2019.

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. Applications of Remote Sensing in Precision Agriculture: A Review. **Remote Sensing**, v. 12, n. 19, p. 3136, 2020.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. **AI 2006: Advances in Artificial Intelligence: 19th Australian Joint Conference on Artificial Intelligence**, p. 1015–1021, 2006.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and remote sensing**, v. 52, n. 3, p. 397–399, 1986.

SU, W.-H.; FENNIMORE, S. A.; SLAUGHTER, D. C. Fluorescence imaging for rapid monitoring of translocation behaviour of systemic markers in snap beans for automated crop/weed discrimination. **Biosystems Engineering**, v. 186, p. 156–167, 2019.

TRIMBLE. Receptor GNSS SP60: Manual do Usuário. 2016. Disponível em: <https://spectrageospatial.com/wp-content/uploads/SP60_UG_br_C.pdf>. Acesso em: 4 fev. 2023.

UNDESA - UNITED NATIONS DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS. **World Population Prospects 2022: Summary of Results**, 2022. Disponível em: <https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/wpp2022_summary_of_results.pdf>. Acesso em: 3 fev. 2023.

VALENTE, J.; DOLDERSUM, M.; ROERS, C.; KOOISTRA, L. DETECTING RUMEX OBTUSIFOLIUS WEED PLANTS IN GRASSLANDS FROM UAV RGB IMAGERY USING DEEP LEARNING. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. IV-2/W5, p. 179–185, 2019.

VAN DEN BERG, H.; GU, B.; GRENIER, B.; KOHLSCHMID, E.; AL-ERYANI, S.; DA SILVA BEZERRA, H. S.; NAGPAL, B. N.; CHANDA, E.; GASIMOV, E.; VELAYUDHAN, R.; YADAV, R. S. Pesticide lifecycle management in agriculture and public health: Where are the gaps? **Science of the Total Environment**, v. 742, 2020.

VASCONCELOS, Y. Agrotóxicos na berlinda. **Pesquisa FAPESP**, v. 19, p. 18–27, set. 2018. Disponível em: <https://revistapesquisa.fapesp.br/wp-content/uploads/2018/09/018-027_CAPA-Agrot%C3%B3xicos_271.pdf>. Acesso em: 28 jan. 2023.

VAUTARD, R.; YIOU, P.; GHIL, M. Singular-spectrum analysis: A toolkit for short, noisy chaotic signals. **Physica D: Nonlinear Phenomena**, v. 58, n. 1–4, p. 95–126, 1992.

VITORINO, H. dos S.; JUNIOR, A. C. da S.; GONÇALVES, C. G.; MARTINS, D. Interference of a weed community in the soybean crop in functions of sowing spacing. **Revista Ciência Agronômica**, v. 48, n. 4, p. 605–613, 2017.

VIVIAN, R.; SILVA, A. A.; GIMENES, Jr. , M.; FAGAN, E. B.; RUIZ, S. T.; LABONIA, V. Dormência em sementes de plantas daninhas como mecanismo de sobrevivência: breve revisão. **Planta Daninha**, v. 26, n. 3, p. 695–706, 2008.

VOLL, E.; ADEGAS, F. S.; GAZZIERO, D. L. P.; BRIGHENTI, A. M.; OLIVEIRA, M. C. N. de. Amostragem do banco de semente e flora emergente de plantas daninhas. **Pesquisa Agropecuária Brasileira**, v. 38, n. 2, p. 211–218, 2003.

WANG, A.; ZHANG, W.; WEI, X. A review on weed detection using ground-based machine vision and image processing techniques. **Computers and Electronics in Agriculture**, v. 158, p. 226–240, 2019.

WANG, L.; CHU, F.; XIE, W. Accurate Cancer Classification Using Expressions of Very Few Genes. **IEEE/ACM Transactions on Computational Biology and Bioinformatics**, v. 4, n. 1, p. 40–53, 2007.

WESTWOOD, J. H.; CHARUDATTAN, R.; DUKE, S. O.; FENNIMORE, S. A.; MARRONE, P.; SLAUGHTER, D. C.; SWANTON, C.; ZOLLINGER, R. Weed Management in 2050: Perspectives on the Future of Weed Science. **Weed Science**, v. 66, n. 3, p. 275–285, 2018.

YU, J.; SHARPE, S. M.; SCHUMANN, A. W.; BOYD, N. S. Detection of broadleaf weeds growing in turfgrass with convolutional neural networks. **Pest Management Science**, v. 75, n. 8, p. 2211–2218, 2019.

ZHAI, Z.; MARTÍNEZ, J. F.; BELTRAN, V.; MARTÍNEZ, N. L. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, v. 170, p. 105256, 2020.

ZHANG, H.; ALDANA-JAGUE, E.; CLAPUYT, F.; WILKEN, F.; VANACKER, V.; VAN OOST, K. Evaluating the potential of post-processing kinematic (PPK) georeferencing for UAV-based structure- from-motion (SfM) photogrammetry and surface change detection. **Earth Surface Dynamics**, v. 7, n. 3, p. 807–827, 2019.