



# COINTER PDVAgro 2022

VII CONGRESSO INTERNACIONAL DAS CIÊNCIAS AGRÁRIAS

Edição 100% virtual | 29, 30 de nov a 1 de dez

ISSN: 2526-7701 | PREFIXO DOI: 10.31692/2526-7701

## INTELIGÊNCIA ARTIFICIAL NO CONTROLE DE PLANTAS DANINHAS: PERSPECTIVAS E REFINAMENTOS

## INTELIGENCIA ARTIFICIAL EN EL CONTROL DE LAS MALAS HIERBAS: PERSPECTIVAS Y PERFECCIONAMIENTOS

## ARTIFICIAL INTELLIGENCE IN WEED CONTROL: PERSPECTIVES AND REFINEMENTS

Apresentação: Comunicação Oral

Túlio Mazetti Marra<sup>1</sup>; Yara Karine De Lima Silva<sup>2</sup>; Carlos Eduardo Angeli Furlani<sup>3</sup>

DOI: <https://doi.org/10.31692/2526-7701.VIICOINTERPDVAgro.0033>

### RESUMO

A necessidade de incluir tecnologia no campo, visando ganho de precisão e auxílio na vida do produtor agrícola, vem abrindo cada vez mais espaço para o uso de ferramentas de *machine learning* e inteligência artificial (IA). Através da utilização da IA, é possível gerar uma economia significativa de volume de herbicida, sem perder eficiência na redução da interferência das plantas daninhas, o que fundamenta a agricultura digital e de precisão. Nessa circunstância, revisamos artigos científicos na base Scopus sobre *deep learning* (DL) e plantas daninhas, utilizando as palavras-chave “*deep learning*” e “*weed*” no período de 2013 até 2022, onde os artigos foram escolhidos criteriosamente, levando em consideração fatores como a qualidade da pesquisa e abrangência do assunto abordado dentro do escopo desta revisão. Essas práticas são favoráveis ao produtor, uma vez que o mesmo consegue reduzir o custo de controle químico e aumenta a eficiência do processo, além de evitar a poluição ambiental. O DL permite o controle automatizado por robôs e a pulverização localizada de herbicidas, sendo totalmente plausível pensar na possibilidade de superar a dependência de mão de obra e controle químico com preços elevados. Esse tipo de ferramenta fornece o benefício do auxílio da tomada de decisão por parte do agricultor, onde ele pode agir de maneira eficiente na hora e no lugar correto, seja para mapear, replantar ou fertilizar áreas que produzem fontes de alimentos ou bioenergia. Tal tecnologia é flexível e se adequa bem em diferentes lavouras. Assim, podemos explorá-los estrategicamente para pulverizar ingredientes ativos e espalhar bioagentes entomopatogênicos (por exemplo, *Cotesia flavipes* e *Thricogramma spp.*) no campo, em quaisquer lugares estratégicos, visando suprimir pragas economicamente relevantes (por exemplo, *Diatraea saccharalis*, *Mahanarva fimbriolata*, vírus do mosaico da cana-de-açúcar e ervas daninhas) com mais precisão e responsabilidade ambiental do que é possível com as abordagens tradicionais, evitando tráfego intenso de maquinário e contato com o objeto. Isso mostra que os *insights* sobre as informações resultantes de nossa revisão integrativa são oportunos. Eles fornecerão conhecimento para progredir na proeminência do campo na operação de máquinas voadoras (aviões e VANT's), visando sempre elevar o custo-benefício da produção de cana-de-açúcar com foco nos maiores desafios do setor, como alcançar a segurança alimentar e energética, prosperando em um mundo

<sup>1</sup>Eng. De Biosistemas e Mestrando em Produção Vegetal, UNESP-Jaboticabal SP, [tulio.marra@unesp.br](mailto:tulio.marra@unesp.br)

<sup>2</sup>Eng. Agrônoma, MSc. Produção Vegetal e Doutorado em Ciência do Solo, UNESP-Jaboticabal SP, [yara.karine@unesp.br](mailto:yara.karine@unesp.br)

cada vez mais desafiador.

**Palavras-Chave:** artificial intelligence; weeds; deep learning

## RESUMEN

La necesidad de incluir la tecnología en el campo, con el objetivo de ganar precisión y ayudar en la vida del productor agrícola, está abriendo cada vez más espacio para el uso de herramientas de aprendizaje automático e inteligencia artificial (IA). Mediante el uso de la IA, es posible generar un importante ahorro en el volumen de herbicidas, sin perder eficiencia en la reducción de la interferencia de las malas hierbas, que es la base de la agricultura digital y de precisión. En esta circunstancia, se revisaron artículos científicos en la base de datos de Scopus sobre el aprendizaje profundo (DL) y las malas hierbas, utilizando las palabras clave "deep learning" y "weed" en el período comprendido entre 2013 y 2022, donde los artículos fueron elegidos cuidadosamente, teniendo en cuenta factores como la calidad de la investigación y la exhaustividad del tema abordado en el ámbito de esta revisión. Estas prácticas son favorables para el productor, ya que pueden reducir el coste del control químico y aumentar la eficiencia del proceso, además de evitar la contaminación ambiental. El DL permite el control automatizado mediante robots y la pulverización localizada de herbicidas, siendo totalmente plausible pensar en la posibilidad de superar la dependencia de la mano de obra y el control químico con altos precios. Este tipo de herramienta ofrece la ventaja de apoyar la decisión del agricultor, que puede actuar eficazmente en el momento y el lugar adecuados, ya sea para cartografiar, replantar o fertilizar las zonas que producen fuentes de alimentos o bioenergía. Esta tecnología es flexible y se adapta bien a diferentes cultivos. De este modo, podemos explotarlo estratégicamente para pulverizar ingredientes activos y esparcir bioagentes entomopatógenos (por ejemplo, *Cotesia flavipes* y *Thricogramma* spp.) en el campo en cualquier lugar estratégico para suprimir plagas económicamente relevantes (por ejemplo, *Diatraea saccharalis*, *Mahanarva fimbriolata*, el virus del mosaico de la caña de azúcar y las malas hierbas) con más precisión y responsabilidad medioambiental de lo que es posible con los enfoques tradicionales, evitando el tráfico de maquinaria pesada y el contacto con objetos. Esto demuestra que la información resultante de nuestra revisión integradora es oportuna. Aportarán conocimientos para avanzar en el protagonismo del campo en la operación de máquinas voladoras (aeronaves y vehículos aéreos no tripulados), siempre con el objetivo de elevar la rentabilidad de la producción de la caña de azúcar con un enfoque en los mayores desafíos del sector, como lograr la seguridad alimentaria y energética, prosperando en un mundo cada vez más desafiante.

**Palabras Clave:** artificial intelligence; weeds; deep learning

## ABSTRACT

The need to include technology in the field, aiming to gain precision and aid in the life of the agricultural producer, is increasingly opening space for the use of machine learning and artificial intelligence (AI) tools. Through the use of AI, it is possible to generate significant savings in herbicide volume, without losing efficiency in reducing weed interference, which is the basis of digital and precision agriculture. In this circumstance, we reviewed scientific articles in the Scopus database about deep learning (DL) and weeds, using the keywords "deep learning" and "weed" in the period from 2013 to 2022, where the articles were chosen carefully, taking into account factors such as the quality of the research and comprehensiveness of the subject addressed within the scope of this review. These practices are favorable to the producer, since they can reduce the cost of chemical control and increase the efficiency of the process, besides avoiding environmental pollution. DL allows automated control by robots and localized spraying of herbicides, and it is entirely plausible to think of the possibility of overcoming the dependence on labor and high-priced chemical control. This kind of tool provides the benefit of decision support for the farmer, where he can act efficiently at the right time and in the right place, whether to map, replant, or fertilize areas that produce food sources or bioenergy. Such technology is flexible and fits well in different crops. Thus, we can strategically exploit it to spray active ingredients and spread



entomopathogenic bioagents (e.g. *Cotesia flavipes* and *Thricogramma* spp.) in the field at any strategic locations to suppress economically relevant pests (e.g. *Diatraea saccharalis*, *Mahanarva fimbriolata*, sugarcane mosaic virus, and weeds) with more precision and environmental responsibility than is possible with traditional approaches, avoiding heavy machinery traffic and object contact. This shows that insights into the information resulting from our integrative review are timely. They will provide knowledge to advance the field's prominence in operating flying machines (aircraft and UAVs), always aiming to raise the cost-effectiveness of sugarcane production with a focus on the industry's biggest challenges, such as achieving food and energy security while thriving in an increasingly challenging world.

**Keywords:** artificial intelligence; weeds; deep learning

## INTRODUÇÃO

O manejo inteligente de culturas trabalha com a redução da quantidade de defensivos agrícolas utilizados, com o objetivo de reduzir fatores econômicos, além de adversidades ambientais e sociais. As plantas daninhas afetam drasticamente o crescimento inicial de culturas, limitando a produtividade (MACLAREN et al., 2020), reduzindo a mesma de 10 a 100% (TOĞAÇAR, 2022), compondo-se assim como um dos principais fatores limitantes da produção (WANG et al., 2019).

A alta eficiência faz com que os herbicidas sejam os produtos mais utilizados para controle de plantas daninhas (ALI et al., 2014). Tal manejo é chamado de capina química e é o método mais utilizado desde a década de 1940 (HAMUDA et al., 2016). É comum a prática de pulverizar tais produtos em área total, desconsiderando a incidência localizada dessas plantas em pontos específicos, variabilidade da cultura ou manchas de solo.

Práticas inovadoras e ferramentas tecnológicas tem por objetivo reduzir o custo total de controle químico, melhorando a efetividade do processo, além de mitigar a poluição ambiental (ABDULAH I et al., 2012; ZHU et al., 2018; HERRERA et al., 2014; GERHARDS et al., 2006). O advento de técnicas inteligentes e automatizadas proporciona a possibilidade da detecção das plantas daninhas, o que propicia a realização de uma aplicação localizada de herbicidas, reduzindo a probabilidade de estresse residual na cultura principal. É preciso balizar entre reduzir ao máximo a interferência de plantas daninhas e a quantidade de herbicida a ser utilizada. O controle químico na forma convencional, que é realizado pulverizando toda a área de plantio, acaba por possuir alto custo e é responsável pela geração de problemas ambientais, relacionados a poluição (WANG et al., 2019). Matthews (2018), usando veículo aéreo não tripulado (unmanned aerial vehicle-UAV), para aplicação localizada de herbicidas,



conseguiram reduzir em 40% o total de volume de produto utilizado para aplicação comparado ao método tradicional. Huang et al. (2018) economizaram de 58,3% a 70,8% no consumo de produto total. De Castro et al. (2013) economizaram 61,31% em áreas sem tratamento e 13,02% com a prática de baixa dose de herbicida. Gerhards et al. (2006) verificaram uma economia de até 81% de herbicidas no controle localizado de plantas daninhas sem que houvesse redução do rendimento de culturas.

A qualidade de pulverização também é um aspecto importante para a aplicabilidade do controle químico. A eficiência dos herbicidas é reduzida quando o produto é aplicado fora do alvo ou caso aja deriva das gotas na pulverização, o que implica no risco de fitotoxicidade de culturas e poluição do ambiente. Wang et al. (2021) conseguiram bons resultados na detecção de gotas de pulverização dimensionando a qualidade da aplicação aérea de pesticidas com UAV pelo modelo de aprendizagem profundo MobileNet\_SSD. O uso de UAV pode contribuir nesse sentido, uma vez que sua utilização possibilita a detecção mais rápida dos parâmetros de deposição das gotículas com os produtos, que podem ser ajustados. Terra et al. (2021) demonstraram que é possível modernizar pulverizadores convencionais utilizando um sistema modular de agricultura de precisão (AP) através de robôs baseados em visão de máquina para otimizar a aplicação de defensivos controlando individualmente a abertura de bicos. Chand et al. (2021) propuseram um novo robô agrícola inteligente multifuncional baseado em internet das coisas (IoT) e visão computacional que ajudou a automatizar a aplicação de produtos e irrigação. O uso desse tipo de dispositivo proporciona a possibilidade de monitoramento da orientação horizontal e vertical dos bicos de pulverização por infravermelho.

Quando em estágio de desenvolvimento inicial, as plantas daninhas são mais facilmente controláveis. Logo, quanto mais antecipadamente ocorrer a identificação das mesmas, mais cedo é possível realizar a escolha específica do herbicida que será utilizado. A grande vantagem da identificação e controle precoce de plantas invasoras é a possibilidade de realizar o controle químico também de maneira antecipada, permitindo que as culturas possam se desenvolver de forma livre e sem competição, desde os estágios iniciais de desenvolvimento (JABIR e FALIH, 2022). Esta abordagem deve ser buscada para reduzir o tempo de competição das plantas por água, luz e nutrientes (SHOREWALA et al., 2021). A correlação entre a perda de produtividade e a competição é forte (HAMUDA et al., 2016; MCCARTHY et al., 2010; SLAUGHTER et



al., 2008). Quando aplicados em estádios tardios, a quantidade de produtos utilizados pelos produtores em campo tende a ser maior, o que gera aumento de gastos e de poluição do ambiente de cultivo.

Já é provado por meio de estudos que o uso de herbicidas possui potencial de poluição e impacto na saúde de seres vivos (JABIR et al., 2021). O uso de maneira inadequada de agrotóxicos são um grave problema para a saúde pública (NAGABOOSHANAM et al., 2021). A presença acima dos níveis toleráveis dessas substâncias tóxicas nos alimentos, no ar, no solo e na água podem causar problemas à saúde pública, como doenças respiratórias, distrofia muscular, depressão, distúrbios neurológicos e até a morte em seres humanos (BATTAGLIN et al., 2016; SUDDABY et al., 2016).

Por este motivo, a aprendizagem profunda (*deep learning-DL*) pode auxiliar no que tange esses problemas, automatizando o processo de identificação e controle de plantas daninhas com eficiência, de forma localizada e precisa, com menor volume de produtos. Isso resulta em menor produção de resíduos de moléculas químicas no ambiente, diminuindo possíveis impactos naturais, que também atinge o consumo de combustíveis fósseis necessários para o desenvolvimento, produção e transporte de tais produtos. Nesse sentido, as mudanças climáticas também são afetadas, além do efeito positivo no meio ambiente devido ao manejo específico no local (SSWM), o setor econômico e social da agricultura também são beneficiados, já que promover a melhoria do controle químico de daninhas gera redução do custo de produção e aumenta a produtividade total (TOĞAÇAR, 2022). O custo dos insumos agrícolas é baseado em todo o processo de produção e logística de abastecimento da cadeia de suprimentos no comércio consumidor. Esse fato reflete diretamente no campo social de redução de custo dos produtos alimentícios aos consumidores finais, aumentando seu poder de compra, promovendo maior desenvolvimento humano, além de segurança alimentar.

## FUNDAMENTAÇÃO TEÓRICA

Segui-se o protocolo PRISMAS descrito por Page et al. (2021) para estruturar a busca da literatura científica para a construção desta revisão. PRISMAS consiste no direcionamento da busca de documentos científicos (artigos, livros etc) para o levantamento do estado da arte à luz de um dado tema.



Primeiramente realiza-se a busca com palavras-chave para que posteriormente os trabalhos possam ser filtrados de acordo com a aderência ao tema proposto. Utilizou-se a junção das palavras-chaves “*deep learning*” and “*weed*” na plataforma Scopus. Esta plataforma foi escolhida por conter base de dados científicos atualizados a nível global.

Durante o processo de exploração da base de dados são utilizados critérios de elegibilidade:

1. Artigo original
2. Do ano 2013 ao ano 2022
3. Correlação à temática da revisão
4. Descrição minuciosa da experimentação

Após isso, faz-se a extração e análise dos dados contidos nos artigos filtrados:

1. Cria-se uma lista dos artigos no Scopus
2. Exporta-se a lista pelo Scival dentro do Scopus
3. As informações geradas pelo Scival são analisadas
4. Realiza-se uma leitura do título e resumo para que os trabalhos sejam finalmente selecionados para a leitura minuciosa do conteúdo de cada artigo para o desenvolvimento da revisão.

## **METODOLOGIA**

Para realização da revisão, foi efetuada uma busca avançada de artigos científicos na base Scopus utilizando as palavras-chave “*deep learning*” e “*weed*”, no período de 2013 até 2022.

A busca rendeu um total de 290 artigos científicos, os quais foram selecionados criteriosamente artigos pela qualidade da pesquisa e pela abrangência do assunto abordado dentro do escopo desta revisão.

## **RESULTADOS E DISCUSSÃO**

### **Deep learning: aplicabilidades na promoção da agricultura sustentável**

A agricultura moderna busca, através da manipulação informações adquiridas por ferramentas inovadoras e tecnológicas, otimizar processos para garantir a possibilidade de assumir diferentes técnicas de manejo. Por meio da utilização de ferramentas de DL, torna-se



possível administrar e articular dados, não só para controlar as plantas daninhas, mas também manejar fertilização, irrigação e fenotipagem (AMEND et al., 2019), além de análise de outros processos, desde o plantio até a colheita. A aplicabilidade da DL no campo é um tema e uma ferramenta que é inerente ao desenvolvimento e utilização da AP. Conjuntos de dados contendo diferentes espécies de plantas daninhas utilizando DL são disponibilizados publicamente (OLSEN et al., 2019; PATIDAR et al., 2020). Estes bancos de dados com aplicação agrícola vêm aumentando significativamente desde 2015, e essa aquisição e compartilhamento de informações são de suma importância quando se tem por objetivo promover o desenvolvimento da AP. Isso torna, gradativamente, o treinamento de algoritmos mais robusto e o poder de tomadas de decisão com visão de máquina acaba se aprimorando a medida que esses bancos de dados aumentam e são mais utilizados.

A Inteligência Artificial (IA) pode ser a solução para superar desafios da produção agrícola, como o custo crescente de defensivos agrícolas e a diminuição da disponibilidade de mão de obra para operações de campo, que acabam sendo fatores restritivos, a nível global, do controle manual e mecanizado de plantas daninhas. A atuação do homem para modificar o ambiente pode ser enormemente impactada pela IA, desempenhando um papel importante no cotidiano social. A IA e a IoT são tecnologias que já vem sendo inseridas no contexto agrícola, e tem potencial infinito para fazer com que aja uma conversão da agricultura tradicional para a moderna, onde há otimização no uso de recursos, melhora do controle de plantas daninhas, redução da mão de obra humana, melhor gerenciamento das colheitas e gestão da cadeia de abastecimento (KATIYAR e FARHANA, 2021). A DL é uma das abordagens mais relevantes da IA, porque vem mostrando seu potencial de aplicabilidade no campo, ultrapassando barreiras operacionais que ameaçam a segurança alimentar.

A classificação de plantas por DL permite que o controle químico seja feito de maneira automatizada, através do uso de robôs e pela pulverização localizada de herbicidas, sendo totalmente plausível superar a dependência de mão de obra e a elevação do custo de herbicidas. Amend et al. (2019) destacaram os sucessos da DL na distinção das plantas daninhas com precisão média de cerca de 93% e precisão total de 98,4% (AMEND et al., 2019). Não há limitação no uso da DL, pois o algoritmo aprende por conta própria, tendo sua capacidade de decisão ilimitada, devido ao melhoramento de seu treinamento conforme a entrada de dados ao



longo do tempo (MOAZZAM et al., 2019). Além disso, pode ser utilizado para aplicações online no campo pela base de funcionamento e capacidade de processar dados mais rapidamente após o treinamento.

A AP com IA leva em consideração aspectos importantes de variação de informação, como a variabilidade temporal e espacial de atributos, o que melhora o manejo voltado a sustentabilidade e individualidade de cada produção agrícola (ISPA, 2022). Diferentes aplicações da AP têm sido utilizadas para identificar plantas daninhas, monitorar a saúde das plantas e do solo, criar zonas de manejos de diferentes culturas e proporcionar uma colheita inteligente (XIONG et al., 2019).

Fatores climáticos e escassez hídrica afetam a produtividade dentro de qualquer propriedade rural. A IA como mecanismo, é capaz de mitigar esses problemas (RADOGLU-GRAMMATIKIS et al., 2020). Na IA podem ser utilizados dados e informações de baixo custo, de maneira simplificada, visando resolver problemas no campo, através do uso de sistemas de automação. Na atual conjectura do cenário tecnológico mundial, uma extensa gama de dados é disponibilizada de forma gratuita. Índices de vegetação (IV) extraídos de imagem de satélite ou UAVs com câmeras embarcadas são exemplos de dados de baixo custo. Os IV possuem boa correlação com o crescimento inicial de locais com ou sem incidência de plantas daninhas (ALMEIDA et al., 2015).

O monitoramento do comportamento espectral de uma cultura é muito importante, devido a acessibilidade facilitada das informações necessárias, que podem ser coletadas em qualquer lugar do mundo. A densidade de plantas daninhas, além da identificação e localização das mesmas, é um parâmetro essencial para um efetivo controle químico, podendo ser feito através de UAVs com sensores embarcados, coletando imagens RGB ou multiespectrais da lavoura analisada (OSORIO et al., 2020). Shorewala et al. (2021) obtiveram sucesso na detecção de plantas daninhas utilizando robô autônomo e um sistema semi-supervisionado para calcular a densidade e distribuição para realização do controle. Essa metodologia ainda pode ser extrapolada para a identificação de doenças, já que algumas plantas daninhas são hospedeiras secundárias de agentes patogênicos, nematoides ou pragas, contribuindo ainda mais com a produtividade, rentabilidade e qualidade dos produtos agrícolas (JABIR e FALIH, 2022). Os desenvolvimentos tecnológicos estão avançando, sendo cada vez mais





implementados em terras destinadas as pequenas e grandes produções, sempre com o intuito de aumentar a produtividade de tais culturas (TALAVIYA et al., 2020).

A criação de um banco de dados unindo informações compartilhadas do monitoramento espectral com parâmetros de produção podem ser utilizados em sistemas de DL para controle localizado de plantas daninhas. Características extraídas de imagens como a morfologia, comportamentos espectrais, texturas visuais e contextos espaciais, em geral, são parâmetros responsáveis por cumprir a função de identificação de plantas daninhas (WANG et al., 2019). Além de IV, outros dados auxiliam a visão de máquina, como avaliações de espectroscopia de infravermelho próximo e visível, técnicas multi e hiperespectral, fluorescência, variação de detecção e alcance de luz (Light Detection and Ranging-LiDAR) e ultrassônica. Pontos críticos na detecção e diferenciação de plantas daninhas podem ser levados em consideração para romper as dificuldades de discriminação entre culturas e plantas daninhas com propriedades semelhantes (Tabela 01).

**Tabela 01:** Como captar características que permitem discriminar plantas daninhas das culturas.

Características	Descrição	Referências
Diferenças morfológicas	A estrutura e o formato das folhas e parte aérea das plantas são distinguíveis.	Slaughter et al. (2008); Weis e Sökefeld (2010); Ahmed et al. (2012); Slaughter (2013)
Estágio de crescimento	Em estágios mais tardios há a obstrução das folhas e diferenciação das propriedades morfológicas, texturais e espectrais das folhas.	Lin (2009); López-Granados (2011); Romeo et al. (2013); Shaner e Beckie (2014); Wang et al. (2019); Fernández-Quintanilla et al. (2018)
Distribuição e densidade	Contexto espaciais e informações de posição ajudam a melhorar a precisão de diferenciação.	Wu et al. (2011); Midtiby et al. (2016)
Condições ambientais	Iluminação, grau de incidência de raios solares e condições de campo no momento da coleta de dados.	Bai et al. (2014); Wang et al. (2019); Darwin et al. (2021); Jabir e Falih (2022)

**Fonte:** Própria (2019)

Soluções mais eficientes reduzem custos de produção e valorizam a saúde humana (SAKYI, 2019). A automação de processos agrícolas tem se desenvolvido baseada nos pilares do custo de produção, valorização da saúde humana e questões ambientais (LIU e BRUCH,



2020). A redução da mão de obra no campo e proteção do meio ambiente de contaminação são vantagens trazidas por essas automações (HASAN et al., 2021). Através dessas tecnologias, é possível destinar robôs para auxiliar no manejo de plantas daninhas de forma verdadeiramente autônoma. Para que isso seja possível, é necessário que os robôs consigam monitorar a cultura, as plantas daninhas e as condições de campo, decidir quando será realizada a capina, determinar o tipo ideal de manejo, atuando em todos os ajustes para o controle (MERFIELD, 2016). Dessa forma, o controle de plantas daninhas se torna mais fácil, eficiente e conseqüentemente mais barato. Nesse contexto a DL é definitivamente aplicável no controle seletivo das plantas daninhas para garantir o rendimento comercial de culturas (FERREIRA et al., 2019; WANG et al., 2019).

### **DL em aspectos práticos da automação**

A prática tradicional de pulverização em área total trás consigo vários aspectos negativos, como o elevado custo e as questões prejudiciais no que tangem a biodiversidade do solo, a qualidade da água potável e a saúde humana (SHARMA et al., 2017). Os custos são elevados porque há a pulverização de herbicidas de maneira uniforme em todo o campo, com ou sem a presença de plantas daninhas nos locais aplicados (JHA et al., 2019). Identificar plantas daninhas com IA possibilita manejos autônomos, programáveis e precisos, que impactam áreas além do cultivo de culturas.

A tecnologia e a informática vêm sendo inseridos no setor agrícola desde 1983 (JHA et al., 2019). Desde então, múltiplos ganhos na economia e no desenvolvimento da agricultura têm sido lapidados em processos mais tangíveis e confiáveis. A automação vem ganhando e exigindo espaço, uma vez que o aumento da produtividade, independente de aumento de área lavrada, exige a adoção de novos padrões, sendo benéfica frente ao aumento dos custos de mão de obra e a preocupação com as questões ambientes e de saúde humana (LIU e BRUCH, 2020; HASAN et al., 2021). Robôs diminuem a exposição de operadores a defensivos e reduz os riscos de intoxicação (BERENSTEIN et al., 2017). Sistemas automatizados removem plantas daninhas e garantem a pulverização seletiva, precisa e localizada para minimizar o uso de herbicidas (LAMESKI et al., 2018).

Robôs automatizados já viabilizam o controle localizado do mato na lavoura (SHOREWALA et al., 2021). Nesse sistema há a extração de informações de simples imagens,



por exemplo, por visão de máquina. Porém, ainda existem alguns desafios a serem superados no controle de plantas daninhas usando imagens, como trabalhar com variações da própria imagem das plantas, da iluminação, das oclusões das folhas e das fases de crescimento em diferentes condições em campo (JABIR e FALIH, 2022). Limitações relacionadas a questões de tempo, trabalho e operações manuais tem sido superadas pela utilização de técnicas de processamento de imagens e abordagens de DL (WANG et al., 2019; MILIOTO et al., 2018). Sistemas inteligentes de controle dependem do desempenho do sistema de visão artificial e a DL possibilita a classificação e localização de plantas daninhas com êxito (JABIR e FALIH, 2022). Jabir e Falih (2022) demonstraram a eficácia do aprendizado profundo para identificar plantas daninhas em tempo real, com a ferramenta adaptada em sistemas automatizados e inteligentes de pulverização localizada.

O sucesso da detecção e controle de plantas daninhas através de imagens, permeia quatro etapas importantes dentro de todo o processo: pré-processamento das imagens, segmentação, extração das características identificáveis e classificação (WANG et al., 2019). A etapa mais complexa é a segmentação (CLOSE e SABZI et al., 2018). Por esse motivo, essa é a etapa mais pesquisada e possui foco de quem trabalha na área, possuindo vasta gama de trabalhos na literatura com resultados promissores. Metodologias como o modelo gaussiano multivariado (HALL et al., 2017), redes neurais convolucionais (POTENA et al., 2017), árvore de decisão (GUO et al., 2013), floresta aleatória (RIEGLER-NURSCHER et al., 2018), classificador Bayesiano (RUIZ-RUIZ et al., 2009), rede neural de propagação regressiva (ZHENG et al., 2009), discriminante linear de fisher (ZHENG et al., 2010) e máquinas de vetor de suporte (GUERRERO et al., 2012) são alguns exemplos de modelos que podem ser utilizados com esse intuito. Não faltam esforços para que algoritmos sejam desenvolvidos, melhorados e treinados, com a finalidade de automatizar robôs para o controle de plantas daninhas, visto que essa abordagem detém um alto potencial para integrar totalmente o futuro de cultivos agrícolas.

Em muitos momentos, como resposta a baixa eficiência do controle tradicional de plantas daninhas, o uso de herbicidas se torna exacerbado e inadequado, causando fitotoxicidade e conseqüentemente danos quantitativos e qualitativos às culturas comerciais. Muitos países restringem o seu uso, na tentativa de combater problemas causados por estes



produtos (HAMUDA et al., 2016). A avaliação de danos nas culturas causados por herbicidas que foram aplicados fora do alvo é feita de forma visual ou medindo respostas biométricas, porém são métodos trabalhosos, demorados e não aplicáveis em culturas com grande extensão de área (ZHANG et al., 2021). A IA pode analisar mudanças espectrais, que são avaliações de fácil coleta nas culturas, a fim de fornecer um método para detectar danos por herbicidas (ZHANG et al., 2021). Dados multispectrais e outros mecanismos também podem diferenciar danos causadas por herbicidas, o que os torna essencialmente práticos do ponto de vista do manejo de grandes culturas. A possibilidade de recuperação das plantas e severidade dos danos causados por herbicidas através da utilização de técnicas de sensoriamento hiperespectral e modelos de aprendizado da máquina são temas tratados nos trabalhos de Bloem et al. (2020) e Huang et al. (2018). Zhang et al. (2021) avaliaram danos por glifosato e recuperação na cultura do milho, utilizando índices espectrais e algoritmos de *machine learning*, e encontraram precisão superior à 95% nas plantas recuperáveis e irrecuperáveis.

#### **Conexão de tecnologias: sensores, *blockchain* e DL**

O futuro da agricultura se baseia muito nas atuais habilidades tecnológicas inseridas no campo e a conectividade de dados entre setores. O uso bem estruturado de tecnologias desenvolvidas admite melhorias na produção de materiais de qualidade implicando em minimização de perdas e cargas de trabalho (TALAVIYA et al., 2020). É possível conectar e cruzar dados entre os diversos setores de sociedade para embasar cada vez mais as tomadas de decisão.

A *blockchain* e os sensores de baixo custo são exemplos de avanços que estimulam o compartilhamento e coleta de dados a nível global. *Blockchain* é uma tecnologia que armazena e distribui bancos de dados rastreáveis entre os usuários de uma rede. No entanto, para tornar seguro esse movimento, a *blockchain* descentraliza todas as informações com segurança e executa-as de forma inteligente (PARK e LI, 2021). Para complementá-la, o uso de sensores confiáveis e de baixo custo são essenciais para a geração das informações. Os sensores permitirão a coleta maciça de dados no campo de forma menos onerosa e menos variável, gerando sempre o maior número de informações possíveis para imputar na *blockchain*.

Atualmente, vários componentes de medição de diferentes parâmetros são acoplados em maquinários, porém, para que funcionem bem e gerem informações precisas e confiáveis,



existe a necessidade de testes, calibrações e limpeza de maneira constante. Sensores baratos e descartáveis eliminam toda essa necessidade, podendo transformar rapidamente toda a gestão de informações, saúde e cadeia de suprimentos (DINCER et al., 2019). Sensores descartáveis são definidos como dispositivos para detecção de variáveis no campo com custo reduzido e facilidade de uso. Com o aumento do desperdício de alimentos, fator que impacta diretamente a economia, o meio ambiente e a sociedade, estes sensores devem ser largamente desenvolvidos para monitorar os parâmetros de qualidade dos alimentos em praticamente toda a cadeia de suprimentos (DINCER et al., 2019). A atual necessidade de informações rápidas liga os interesses em aumentar os fluxos dessas informações sem onerar os custos. A integração entre a *blockchain* e a DL pode servir como ferramenta para resolver problemas, tanto no campo da agricultura quanto em outros setores. Medidas podem ser tomadas baseadas nas informações contidas na *blockchain* e interpretadas por DL, para tomadas de decisão. Além disso, a *blockchain* também pode ser conectada em redes IoT para melhorar a saúde e a qualidade de produtos para a sociedade, minimizando a produção de resíduos, beneficiando o meio ambiente. Os sensores aqui reportados são práticos e utilizáveis por qualquer pessoa a qualquer hora, sem a preocupação de contaminação e recalibração.

Uma das metas da ONU gira em torno da sustentabilidade. A cadeia de suprimentos aborda todo o processo de transporte, armazenamento e entrega de produtos, do local de produção de matérias-primas até os consumidores finais (ALIYU et al., 2018). Ter uma cadeia sustentável é produzir com qualidade e suprir a demanda de alimentos, sem afetar as gerações futuras. Um grande gargalo para o uso de tecnologias deve ser levado em consideração, aja visto que 2/3 da população mundial estará vivendo até 2050 nas áreas urbanas, segundo a ONU. Isso significa que o campo deve estar cada vez mais conectado as inovações tecnológicas, para cada vez menos depender da mão de obra humana. Tem-se então a importância da IA para automatizar todo e qualquer tipo de processo dentro da cadeia de suprimentos (TALAVIYA et al., 2020). A abordagem de se conectar as tecnologias dos diversos sensores, imputar todas as informações possíveis em uma *blockchain* e aplicar as mesmas na DL viabiliza diversos aspectos que permeiam as atividades agrícolas:

- a) Confiabilidade e rastreabilidade de dados;
- b) Facilidade, rapidez e baixo custo do fluxo de informações;



- c) Gerenciamento das transações na cadeia de suprimentos;
- d) Melhorias de processos e redução de desperdícios;
- e) Redução da mão de obra;
- f) Proteção do meio ambiente.

Além da área agrícola, a *blockchain* é aplicável em empresas de diversos ramos e segmentos, como serviços, saúde e farmacêutica, promovendo o desenvolvimento sustentável das mais diversas áreas (PARK e LI, 2021). Apesar da sua extensão e consequente possibilidade de uso, a qualidade das informações utilizadas também entra como ponto crítico. Assim, os sensores devem atuar sempre produzindo dados confiáveis, tendo alta sensibilidade, seletividade, precisão e estabilidade ao longo do tempo. O desenvolvimento dos sensores descartáveis de baixo custo, com características de detecção superiores, é motivado pela gradual conscientização da sustentabilidade ambiental, poluição do meio ambiente e busca pela segurança alimentar (WCED, 1987). Esses tipos de sensores também possuem vantagem de serem mais sensíveis para realizar os controles ambientais e monitoramento de muitas amostras se comparados aos convencionais (HASSANI et al., 2017). Trabalhos de Guler et al. (2010), Ivanov et al. (2002) e Sassolas et al. (2012) demonstraram que estes sensores são satisfatórios para controle ambiental, triagem da qualidade de alimentos e detecção de defensivos agrícolas.

## CONCLUSÕES

Especificamente, no controle inteligente de plantas daninhas, todos os aspectos aqui mencionados foram criteriosamente selecionados por sua aplicabilidade, a fim de efetivar a busca de desenvolvimento sustentável, visto que a tecnologia *blockchain* está se tornando cada vez mais popular. Diversas bases de conhecimento envolvem a *blockchain*, relacionando os objetivos de desenvolvimento sustentável da ONU no contexto da cadeia de suprimentos, gestão de resíduos (ambiental) e percepção pública (social). A expectativa é trazer e enaltecer o máximo de vantagens possíveis com a utilização da tecnologia, coleta e compartilhamento de informações seguras, além de robustez na interpretação. Nesse sentido, a tomada de decisão torna-se holística nas diversas esferas dentro da agricultura e do mercado consumidor, já que haverá o aumento da eficiência de processos e redução do uso de insumos e de custos que impactam diretamente na cadeia de suprimentos. O gerenciamento dessa cadeia permite a



mitigação das emissões de gases de efeitos estufa e incrementa a saúde e imagem pública do país.

## REFERÊNCIAS

ABDULAH, A.; NASSAB, D. M. A.; NASROLAHZADEH, S.; SALMASI, Z. S.; POURDAD, S. S. Evaluation of wheat-chickpea intercrops as influence by nitrogen and weed management. **Am. J. Agric. Biol. Sci.** v. 7. p. 447–460, 2012.

ALI, A.; STREIBIG, J. C.; CHRISTENSEN, S.; ANDERSON, C. Image- based thresholds for weeds in maize fields. **Weed Res.** v. 55. p. 26-33, 2014.

ALIYU, S.; TOM, A. M.; HARUNA, I.; TAIYE, M. A.; BARAKAT, M. M. The Role of Blockchain Technology Applications in Supply Chain Management. **Int. J. Comput. Math.** v. 1, 2018.

ALMEIDA, A. Q.; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S.; LEITE, F. P. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens TM - landsat 5. **Floresta e Ambiente.** v. 22. p. 368-376, 2015.

AMEND, S.; BRANDT, D.; DI MARCO, D. *et al.* Weed Management of the Future. **Künstl Intell.** v. 33. p. 411–415, 2019.

BATTAGLIN, W. A.; SMALLING, K. L.; ANDERSON, C.; CALHOUN, D.; CHESTNUT, T.; MUTHS, E. Potential interactions among disease pesticides water quality and adjacent land cover in amphibian habitats in the united states. **Sci. Total Environ.** v. 566. p. 320-332, 2016.

BERENSTEIN, R.; EDAN, Y. Human-robot collaborative site-specific sprayer. **J. Field Robot.** v. 34. p. 1519–1530, 2017.

BLOEM, E.; GERIGHAUSEN, H.; CHEN, X. J.; SCHNUG, E. The Potential of Spectral Measurements for Identifying Glyphosate Application to Agricultural Fields. **Agronomy.** v. 10. p. 1409, 2020.

CHAND, A. A.; PRASAD, K. A.; MAR, E.; DAKAI, S.; MAMUN, K. A.; ISLAM, F. R.; MEHTA, U.; KUMAR, N. M. Design and Analysis of Photovoltaic Powered Battery-Operated Computer Vision-Based Multi-Purpose Smart Farming Robot. **Agronomy.** v.11. p. 530, 2021.

CLOSE, S.; SABZI, Y. Abbaspour-Gilandeh, G. García-Mateos. A fast and accurate expert system for weed identification in potato crops using metaheuristic algorithms. **Comput. Ind.** v. 98. p. 80-89, 2018.

DE CASTRO, A. I.; LÓPEZ-GRANADOS, F.; JURADO-EXPÓSITO, M. Broad-scale



cruciferous weed patch classification in winter wheat using QuickBird imagery for in-season site-specific control. **Precis. Agric.** v. 14. p. 392–413, 2013.

DINCER, C. *et al.* Disposable sensors in diagnostics, food, and environmental monitoring. **Adv. Mater.** v. 31. p. 1806739, 2019.

FERREIRA, A. S.; FREITAS, D. M.; DA SILVA, G. G.; PISTORI, H.; FOLHES, M. T. Unsupervised deep learning and semi-automatic data labeling in weed discrimination. **Comput. Electron. Agric.** v. 165. p. 104963 2019.

GERHARDS, R.; OEBEL, H. Practical experiences with a system for site specific weed control in arable crops using real time image analysis and G.P.S. controlled patch spraying. **Weed Res.** v. 46. p. 185–193, 2006.

GUERRERO, J. M.; PAJARES, G.; MONTALVO, M.; ROMEO, J.; GUIJARRO, M. Support Vector Machines for crop/weeds identification in maize fields. **Expert Syst. Appl.** v. 39. p. 11149-11155, 2012.

GULER, G.; CAKMAK, Y.; DAGLI, Z.; AKTUMSEK, A.; OZPARLAK, H. Organochlorine pesticide residues in wheat from Konya region, Turkey. **Food Chem Toxicol.** v. 48. p. 1218–1221, 2010.

GUO, W.; RAGE, U. K.; NINOMIYA, S. Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model. **Comput. Electron. Agric.** v. 96. p. 58–66, 2013.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Comput. Electron. Agric.** v. 125. p. 184-199, 2016.

HASAN, A. S. M. M.; SOHEL, F.; DIEPEVEEN, D.; LAGA, H.; JONES, M. G. K. A survey of deep learning techniques for weed detection from images. **Computers and Electronics in Agriculture.** v. 184, 2021.

HASSANI, S.; MOMTAZ, S.; VAKHSHITEH, F. et al. Biosensors and their applications in detection of organophosphorus pesticides in the environment. **Arch. Toxicol.** v. 91. p. 109–130, 2017.

HERRERA, P. J.; DORADO, J.; RIBEIRO, Á. A novel approach for weed type classification based on shape descriptors and a fuzzy decision-making method. **Sensors.** v. 14. p. 15304–15324, 2014.

HUANG, H.; DENG, J.; LAN, Y.; YANG, A.; DENG, X.; ZHANG, L. A fully convolutional network for weed mapping of unmanned aerial vehicle (uav) imagery. **PloS One.** v. 13, 2018.

ISPA- International Society of Precision Agriculture, 2021. Precision Ag Definition. [online]





Available: <https://www.ispag.org/about/definition>.

IVANOV, A.; LUKACHOVA, L.; EVTUGYN, G. et al. Polyaniline-modified cholinesterase sensor for pesticide determination. **Bioelectrochem.** v. 55. p. 75–77, 2002.

JABIR, B.; FALIH, N. Deep learning-based decision support system for weeds detection in wheat fields. **International Journal of Electrical and Computer Engineering.** v. 12. p. 816-825, 2022.

JABIR, B.; FALIH, N.; RAHMANI, K. Accuracy and Efficiency Comparison of Object Detection Open-Source Models. **International Journal of Online and Biomedical Engineering (iJOE).** v. 17. p. 165–184, 2021.

JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture.** v. 2. p. 1–12, 2019.

KATIYAR, S.; FARHANA, A. Smart Agriculture: The Future of Agriculture using AI and IoT. **Journal of Computer Science.** v. 17. p. 984-999, 2021.

LAMESKI, P.; ZDRAVEVSKI, E.; KULAKOV, A. Review of automated weed control approaches: An environmental impact perspective. **International Conference on Telecommunications.** p. 132-147, 2018.

LIU, B.; BRUCH, R. Weed detection for selective spraying: a review. **Curr. Robot. Reports.** v. 1. p. 19-26, 2020.

MACLAREN, C.; STORKEY, J.; MENEGAT, A.; METCALFE, H.; DEHNEN-SCHMUTZ, K. An ecological future for weed science to sustain crop production and the environment. A review. **Agron. Sustain. Dev.** v. 40. p. 24, 2020.

MATTHEWS, G. Can drones reduce compaction and contamination?. **Int. Pest Control.** v. 60. p. 224–226, 2018.

MCCARTHY, C.; REES, S.; BAILLIE, C. Machine vision-based weed spot spraying: a review and where next for sugarcane? In: Proceedings of the 32nd **Annual Conference** of the Australian Society of Sugar Cane Technologists (ASSCT 2010). Australian Society of Sugar Cane Technologists, 2010.

MERFIELD, C. N. Robotic weeding's false dawn? Ten requirements for fully autonomous mechanical weed management. **Weed Res.** v. 56. p. 340-344, 2016.

MILIOTO, A.; LOTTES, P.; STACHNISS, C. Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in CNNs. **Proc. IEEE Int. Conf. Robot. Autom. (ICRA).** p. 2229-2235, 2018.



MOAZZAM, S. I.; KHAN, U. S.; TIWANA, M. I.; IQBAL, J.; QURESHI, W. S.; SHAH, S. I. A review of application of deep learning for weeds and crops classification in agriculture. **International Conference on Robotics and Automation in Industry (ICRAI)**. p. 1-6, 2019.

NAGABOOSHANAM, S.; SHARMA, S.; ROY, S.; MATHUR, A.; KRISHNAMURTHY, S.; BHARADWAJ, L. M. Development of Field Deployable Sensor for Detection of Pesticide From Food Chain. **IEEE Sensors Journal**. v. 21. p. 4129-4134, 2021.

OLSEN, A.; KONOVALOV, D. A.; PHILIPPA, B.; RIDD, P.; WOOD, J. C.; JOHNS, J.; BANKS, W.; GIRGENTI, B.; KENNY, O.; WHINNEY, J. et al. Deepweeds: A multiclass weed species image dataset for deep learning. **Sci. Rep.** v. 9. p. 1-12, 2019.

OSORIO, K.; PUERTO, A.; PEDRAZA, C.; JAMAICA, D.; RODRIGUEZ, L. A deep learning approach for weed detection in lettuce crops using multispectral images. **AgriEngineering**. v. 2. p. 471-488, 2020.

PAGE, M. J. *et al.* The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. **The BMJ**. v. 372, 2021.

PARK, A.; LI, H. The Effect of Blockchain Technology on Supply Chain Sustainability Performances. **Sustainability**. v. 13. p. 1726, 2021.

PATIDAR, S.; SINGH, U.; SHARMA, S. K. et al. Weed seedling detection using mask regional convolutional neural network. **2020 International Conference on Electronics and Sustainable Commumcatton Systems (ICESC)**. p. 311-316, 2020.

POTENA, C.; NARDI, D.; PRETTO A. Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture. *Advances in Robot Design and Intelligent Control*, Springer International Publishing. p. 105-121, 2017.

RADOGLU-GRAMMATIKIS, P.; SARIGIANNIDIS, P.; LAGKAS, T.; MOSCHOLIOS, I. A compilation of uav applications for precision agriculture. **Comput. Netw.** v. 172. p. 107148, 2020.

RIEGLER-NURSCHER, P.; PRANKL, J.; BAUER, T.; STRAUSS, P.; PRANKL, H. A machine learning approach for pixel wise classification of residue and vegetation cover under field conditions. **Biosyst. Eng.** v. 169. p. 188-198, 2018.

RUIZ-RUIZ, G.; GÓMEZ-GIL, J.; NAVAS-GRACIA, L. M. Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA). **Comput. Electron. Agric.** v. 68. p. 88-96, 2009.

SAKYI, L. **Five General Categories of Weed Control Methods**, 2019. Disponível em: <<https://greenrootltd.com/2019/02/19/five-general-categories-of-weed-control-methods/>>. Acessado em 31.02.22.



SASSOLAS, A.; PRIETO-SIMÓN, B.; MARTY, J. Biosensors for Pesticide Detection: New Trends. **American Journal of Analytical Chemistry**. v. 3. p. 210-232, 2012.

SHARMA, N.; SINGHVI, R. Effects of chemical fertilizers and pesticides on human health and environment: A review. **Int. J. Agricult. Environ. Biotechnol.** v. 10. p. 675-679, 2017.

SHOREWALA, S.; ASHFAQUE, A.; SIDHARTH, R.; VERMA, U. Weed Density and Distribution Estimation for Precision Agriculture Using Semi-Supervised Learning. **IEEE Access**. v. 9. p. 27971-27986, 2021.

SLAUGHTER, D. C.; GILES, D. K.; DOWNEY, D. Autonomous robotic weed control systems: a review. **Comput. Electron. Agric.** v. 61. p. 63-78, 2008.

SUDDABY, L. A.; BEULKE, S.; VAN BEINUM, W.; OLIVER, R. G.; KUET, S.; BROWN, C. D. Long-term experiments to investigate irreversibility in sorption of pesticides to soil. **Chemosphere**. v. 162. p. 40-47, 2016.

TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides **Artif. Intell. Agric.** v. 4. p. 58-73, 2020.

TERRA, F. P.; NASCIMENTO, G. H. D.; DUARTE, G. A. *et al.* Autonomous Agricultural Sprayer using Machine Vision and Nozzle Control. **J. Intell. Robot. Syst.** v. 102. p. 38, 2021.

TOĞAÇAR. Usind DarkNet models and metaheuristic optimezation methods together to detect weeds growing along with seedlings. **Ecological Informatics**. v. 68. p.101519, 2022.

WANG, L. *et al.* A Smart Droplet Detection Approach With Vision Sensing Technique for Agricultural Aviation Application. **IEEE Sensors Journal**. v. 21. p. 17508-17516, 2021.

WANG, W.; ZHANG, T.; WEI, X. A review on weed detection using ground-based machine vision and image processing techniques. **Comput. Electron. Agricult.** v. 158. p. 226-240, 2019.

WCED- World Commission on Environment and Development, Our Common Future, 1987. **Oxford University Press**, Oxford, UK.

XIONG, Y.; PENG, C.; GRIMSTAD, L.; FROM, P. J.; ISLER, V. Development and field evaluation of a strawberry harvesting robot with a cable-driven gripper. **Comput. Electron. Agricult.** v. 157. p. 392-402, 2019.

ZHANG, T.; HUANG, Y.; REDDY, K. N.; YANG, P.; ZHAO, X.; ZHANG, J. Using machine learning and hyperspectral images to assess damages to corn plant caused by glyphosate and to evaluate recoverability. **Agronomy**. v. 11, 2021.



ZHENG, Y.; WANG, L.; CAYANAN, D. F.; DIXON, M. Greenhouse cucumber growth and yield response to copper application. **HortSciencen.** v. 45. p. 771-774, 2010.

ZHENG, L.; ZHANG, J.; WANG, Q. Mean-shift-based color segmentation of images containing green vegetation. **Comput. Electron. Agric.** v. 65. p. 93-98, 2009.

ZHU, J.; WANG, J.; DITOMMASO, A.; ZHANG, C.; ZHENG, G.; LIANG, W.; ISLAM, F.; YANG, C.; CHEN, X.; ZHOU, W. Weed research status, challenges, and opportunities in China. **Crop Prot.** v. 134. p. 104449, 2018.

