

MÉTODOS PARA IDENTIFICAÇÃO DE PLANTAS DANINHAS EM LAVOURAS DE MILHO COM USO DE INTELIGÊNCIA ARTIFICIAL E PROCESSAMENTO DE IMAGENS: REVISÃO DE LITERATURA

METHODS FOR IDENTIFYING WEEDS IN CORN CROPS USING ARTIFICIAL INTELLIGENCE AND IMAGE PROCESSING: LITERATURE REVIEW

Rodrigo Nunes Wessner*  E-mail: rodrigowessner1@gmail.com

Rejane Frozza*  E-mail: frozza@unisc.br

Rolf Fredi Molz*  E-mail: rolf@unisc.br

*Universidade de Santa Cruz do Sul (UNISC), Santa Cruz do Sul, RS, Brasil.

Resumo: As pesquisas baseadas em Inteligência Artificial e Processamento de Imagens com foco em soluções de controle e gerenciamento de pragas na agricultura vêm evoluindo progressivamente ao decorrer dos anos. Identificar e controlar infestações em lavouras é fundamental para o efetivo incremento de produtividade, o que reflete na cadeia de suprimentos da sociedade e na gestão de segurança alimentar. Assim, o objetivo, nesta fase da pesquisa, foi elaborar uma revisão sistemática da literatura, a partir de termos de busca, para identificar métodos e técnicas que vêm sendo utilizadas na identificação de plantas daninhas em lavouras de milho, com a utilização de redes neurais convolucionais. A análise das pesquisas relacionadas ao tema foi realizada de forma quantitativa e qualitativa. Foram selecionados nove trabalhos para um estudo aprofundado, buscando identificar fatores impactantes nos resultados. Também, elaborou-se um comparativo dos trabalhos selecionados com análises e gráficos de correlações entre palavras-chave e autores. Como resultado, os trabalhos encontrados demonstraram bons desempenhos em seus objetivos. Foram destacadas a preocupação em relação à qualidade da base de dados utilizada, bem como a calibração do modelo de rede neural convolucional, conforme especificidade de cada trabalho. Observou-se um avanço significativo na aplicação desses modelos para processamento de imagens em tempo real, permitindo uma resposta ágil e precisa no controle de pragas agrícolas.

Palavras-chave: Redes neurais convolucionais. Agricultura inteligente. Processamento de imagens. Controle inteligente de ervas daninhas. Cultura de milho.

Abstract: Research based on Artificial Intelligence and Image Processing with a focus on pest control and management solutions in agriculture has been progressively evolving over the years. Identifying and controlling crop infestations is essential for the effective increase in productivity, which reflects on society's supply chain and food safety management. Thus, the objective, in this phase of the research, was to elaborate a systematic review of the literature, based on search terms to identify methods and techniques that have been used in the identification of weeds in corn crops, with the use of convolutional neural networks. The analysis of the research related to the theme was carried out quantitatively and qualitatively. Nine studies were selected for an in-depth study, seeking to identify factors impacting the results. Also, a comparison of the selected studies was elaborated with analyses and graphs of correlations between keywords and authors. As a result, the studies found demonstrated good performance in their objectives. The concern regarding the quality of the database used, as well as the calibration of the convolutional neural network model, according to the specificity of each study, were highlighted. There has been a significant advance in the application of these models for real-time image processing, allowing an agile and accurate response in the control of agricultural pests.

Keywords: Convolutional Neural Network. Intelligent Agriculture. Image Processing. Smart Weed Control. Corn Crops.

1 INTRODUÇÃO

O controle inteligente de plantas daninhas emerge como uma inovadora abordagem no manejo sustentável de vegetação indesejável em ambientes agrícolas. Esse paradigma transcende as práticas convencionais, notadamente o uso excessivo de herbicidas, cujas implicações ambientais e de resistência têm motivado a busca por alternativas eficazes e ecologicamente sustentáveis. Também, o gradativo aumento populacional traz a necessidade de mais produção de alimentos e minimização de perdas de culturas através da identificação de doenças (Chen *et al.*, 2021).

A perda de culturas é um ponto relevante de estudos, já que afeta a segurança alimentar global (Scodro; Corso, 2023). Diante dessa situação, identificar plantas daninhas em culturas podem auxiliar na tomada de decisão mais precisa na aplicação de herbicidas em plantações.

No caso das plantas indesejadas, elas crescem e se reproduzem rapidamente, consumindo grandes volumes de água, fertilidade do solo e iluminação (Veeragandham; Santhi, 2022). O controle, feito por herbicidas, pode ser classificado com base no formato das folhas, gramíneas ou folhas largas, sendo possível alcançar melhores resultados quando comparado com uma aplicação em área total (Ferreira *et al.*, 2017).

Nesse cenário surgem abordagens inovadoras para o controle das plantas indesejadas. A aplicação de tecnologias avançadas, como visão computacional, aprendizado de máquina e robótica desempenham um papel fundamental ao permitir a identificação precisa e o monitoramento contínuo das plantas indesejadas, distinguindo-as das culturas desejadas.

Também, a evolução dos recursos computacionais e das Redes Neurais Convolucionais (*Convolutional Neural Networks - CNNs*), permitem o desenvolvimento de novas soluções para o controle desse problema (Divyanth; Ahmad; Saraswat, 2022). Assim, um sistema de reconhecimento inteligente de visão pode controlar equipamentos de máquinas agrícolas para identificar ervas daninhas de maneira precisa e eficiente (Haichen; Qingrui; Guang, 2021).

Estudos recentes vêm sendo conduzidos para identificar o problema das plantas invasoras para diversas culturas. Algumas abordagens e técnicas de identificação enriquecem a área de estudo. No trabalho de Haichen, Qingrui, Guang (2021), foi utilizado o algoritmo de Máquina de Vetor de Suporte (*Support Vector Machines* - SVM) em conjunto com a CNN VGG16. Subeesh *et al.* (2022) utilizaram as CNNs Alexnet, GoogLeNet, InceptionV3, Xception, para identificar ervas daninhas entre pimentões. Garibaldi-Márquez *et al.* (2022), da mesma forma, utilizaram arquiteturas de CNNs para classificar plantas de milho, ervas daninhas de folha estreita e larga.

Outra característica encontrada nos trabalhos é a organização das bases de dados necessárias para o desenvolvimento e validações das aplicações. Haq (2021) realizou a coleta de 400 imagens com o uso de um *drone*, que após a etapa de processamento, resultou em 15.000 novas imagens para a utilização. Fan *et al.* (2023) capturaram 4.837 imagens de plantas daninhas com o uso de uma câmera fotográfica e de um celular. Veeragandham e Santhi (2022) utilizaram uma base coletada especificamente para utilização da pesquisa com 24.816 imagens de amendoim e ervas, e outra encontrada na internet com 5.998 imagens de milho e ervas.

Neste contexto, o objetivo foi elaborar uma revisão sistemática da literatura, com termos de busca definidos pela temática da pesquisa, a fim de identificar métodos e técnicas de inteligência artificial e processamento de imagens utilizadas na identificação de plantas daninhas em lavouras de milho. Uma revisão sistemática passa por relatórios primários existentes, análise em profundidade e descrição da metodologia e resultados (Petersen *et al.*, 2008). Como processo de pesquisa, destaca-se dois passos: i) realização de uma busca inicial na literatura com termos mais gerais sobre o tema de estudo, com foco em tecnologias e agricultura de precisão; ii) realização de uma busca a partir de termos especializados, a fim de aprofundar as pesquisas.

O artigo está organizado nas seguintes seções: a seção 2 apresenta o referencial teórico relacionado à temática da pesquisa, a seção 3 apresenta a metodologia definida e empregada na pesquisa, enquanto a seção 4 descreve os resultados. Por fim, a seção 5 aborda as conclusões.

2 REFERENCIAL TEÓRICO

O referencial teórico baseia-se em dois tópicos principais: Agricultura e Redes Neurais Artificiais.

2.1 Agricultura

O desenvolvimento da agricultura partiu da evolução humana na busca da sobrevivência e da qualidade de vida. Desde o início, foi necessário adequar as técnicas de produção a partir da descoberta de ferramentas e diferentes maneiras de se produzir. Dessa forma, chegou-se no que há hoje, altas tecnologias sendo aplicadas na área de alimentos para a produção em escala.

A partir da Revolução Industrial 3.0, dispositivos tecnológicos foram sendo introduzidos tanto na indústria como também na agricultura, despertando, nesse setor, o potencial que poderia abranger. Assim, a Agricultura 4.0 se identifica pela capacidade de explorar o uso de tecnologias na produção de alimentos, possibilitando a melhoria de processos, controles de pragas, identificação de anomalias, melhoria de qualidade e desperdícios, dentre tantas outras possibilidades.

Já a agricultura de precisão baseia-se na utilização de tecnologias de informação e comunicação em práticas agrícolas, a fim de controlar corretamente o processo de produção e otimizar intervenções (Coulibaly *et al.*, 2022). Implica na utilização de meios tecnológicos, a fim de otimizar os fatores de produção agrícola, aumentando a produção e diminuindo as perdas (Sishodia; Ray; Singh, 2020). Requer a escolha de informações massivas de diferentes fontes e partes do campo, como nutrição do solo, presença de pragas e ervas daninhas, teor de clorofila nas plantas e condições meteorológicas (Shafi, 2019). Promete revolucionar práticas agrícolas aumentando a eficiência da produção e, ao mesmo tempo, reduzir os impactos ambientais (Lu; Young, 2020).

2.2 Redes Neurais Artificiais (RNA)

As redes neurais artificiais (RNAs) são um subcampo da inteligência artificial e do aprendizado de máquina, as quais se baseiam na estrutura e funcionamento do

cérebro humano para solucionar problemas complexos. Segundo Santos *et al.* (2023), a propriedade mais importante das RNAs é de aprender seu ambiente e melhorar seu desempenho, tendo a capacidade de adaptarem seus parâmetros como consequência da sua interação com o meio externo.

Esse modelo computacional consiste em um conjunto interconectado de unidades de processamento, chamados de neurônios artificiais, os quais simulam neurônios humanos. Esses realizam operações matemáticas com o uso de dados de entradas, produzindo respostas conforme a necessidade estabelecida (Haykin, 2009).

As RNAs possuem adaptabilidade e capacidade de lidar com tarefas complexas e não lineares. Sua estrutura permite modelar arquiteturas que aprendem através de exemplos, podendo também ajustarem automaticamente suas conexões durante a etapa de treinamento.

Dentre as RNAs, existem as Redes Neurais Convolucionais (RNCs). Essas são projetadas para processar dados que possuem estrutura em grade, como imagens, vídeos e dados de séries temporais. Assim, sua capacidade de aprender características das imagens as torna poderosas no reconhecimento de padrões de dados visuais, sendo cada vez mais utilizadas na classificação de imagens: imagens médicas, placas de trânsito, objetos e cenas (Souza *et al.*, 2020).

3 MATERIAIS E MÉTODOS

Esta seção descreve o protocolo para desenvolvimento da pesquisa, objetivos e critérios de seleção de trabalhos relacionados ao tema da pesquisa.

3.1 Protocolo de revisão de literatura

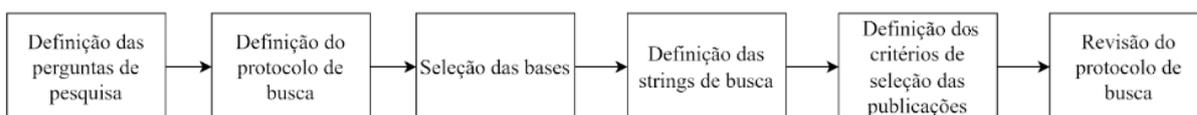
Antes de iniciar o desenvolvimento da revisão sistemática, foi gerado um protocolo contendo o fluxo de trabalho da pesquisa, conforme Klompenburga, Kassahuna e Catal, (2020). Inicialmente, as perguntas com os objetivos foram definidas. Após, foi gerado o protocolo do fluxo de desenvolvimento. Posteriormente, a seleção das bases de busca foi definida, sendo para este estudo a *Science Direct*, *Scopus*, *IEEE* e *ACM*. Para realizar as pesquisas nas bases, foi definida a *string* de busca, bem como os critérios de seleção das publicações. Assim, todos os estudos

relevantes foram extraídos, podendo, eventualmente, responder às questões de pesquisa inicialmente determinadas. O plano de revisão é ilustrado na Figura 1.

Conforme Klompenburga, Kassahuna e Catal (2020), o desenvolvimento da pesquisa de revisão sistemática da literatura é composto por três estágios:

- **Planejamento da revisão**, no qual as perguntas objetivas são definidas, o protocolo é estipulado e tudo o que necessita para realizar a busca e a seleção de documentos necessários, como também a revisão do protocolo inicial.
- **Desenvolvimento da revisão**, que contempla o trabalho de busca nas bases, extração de dados sobre os resultados (informação de autores, ano de publicação, tipo de publicação), a fim de sintetizar os resultados dos trabalhos com características mais próximas às do objetivo buscado.
- **Reportar resultados**, a conclusão da revisão, cujos resultados são documentados e endereçados às perguntas objetivas.

Figura 1 - Detalhes dos passos do plano de revisão



Fonte: Traduzido de Klompenburga, Kassahuna e Catal (2020).

Dessa forma, o planejamento dessa pesquisa baseou-se em realizar uma busca inicial com os termos de busca com escopo mais amplo, a fim de analisar previamente os assuntos atualmente pesquisados. Neste mesmo contexto de planejamento, o trabalho de Schüller *et al.* (2023) exemplifica uma pesquisa realizada com termos de busca. Após, foram especificados os termos de pesquisa com foco no objetivo deste trabalho, de reconhecer plantas daninhas com o uso de redes neurais convolucionais. A partir disso, foram desenvolvidas todas as demais definições e análises posteriormente descritas.

3.2 Pesquisa de planejamento inicial

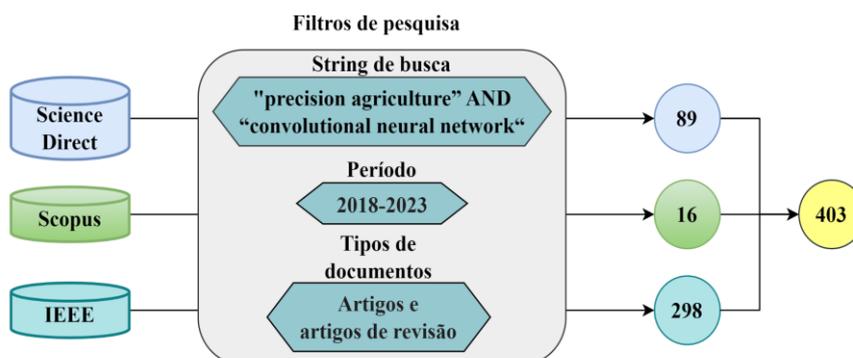
Ao iniciar o desenvolvimento desta pesquisa, houve a necessidade de avaliar o ambiente em um contexto mais amplo. Para isso, foi realizada uma busca com palavras-chaves, mas amplas, de forma a generalizar o objetivo.

Assim, ao definir as bases de *busca Science Direct, Scopus e IEEE*, pesquisou-se pelos termos “*precision agriculture*” e “*convolutional neural network*”. O termo agricultura de precisão engloba a área de atuação da pesquisa e redes neurais artificiais convolucionais a tecnologia que pode ser aplicada. Também, filtrou-se a busca pelos últimos cinco anos (2018-2023), como os tipos de documentos para artigos e artigos de revisão.

Os resultados desta busca inicial são ilustrados na Figura 2. A *string* de busca, conectando os termos de busca pelo operador AND, totalizou 403 documentos. A base Science Direct obteve 89 documentos, a Scopus 16 e a IEEE 298.

Com isso, foi possível observar que há uma quantidade considerável de pesquisas sendo desenvolvidas na área da agricultura de precisão utilizando redes neurais convolucionais. Contudo, o resultado obtido ainda é bastante amplo para uma análise mais criteriosa. Assim, foram gerados alguns mapas gráficos utilizando a ferramenta *VosViewer*, a fim de identificar o processo temporal ao longo dos anos.

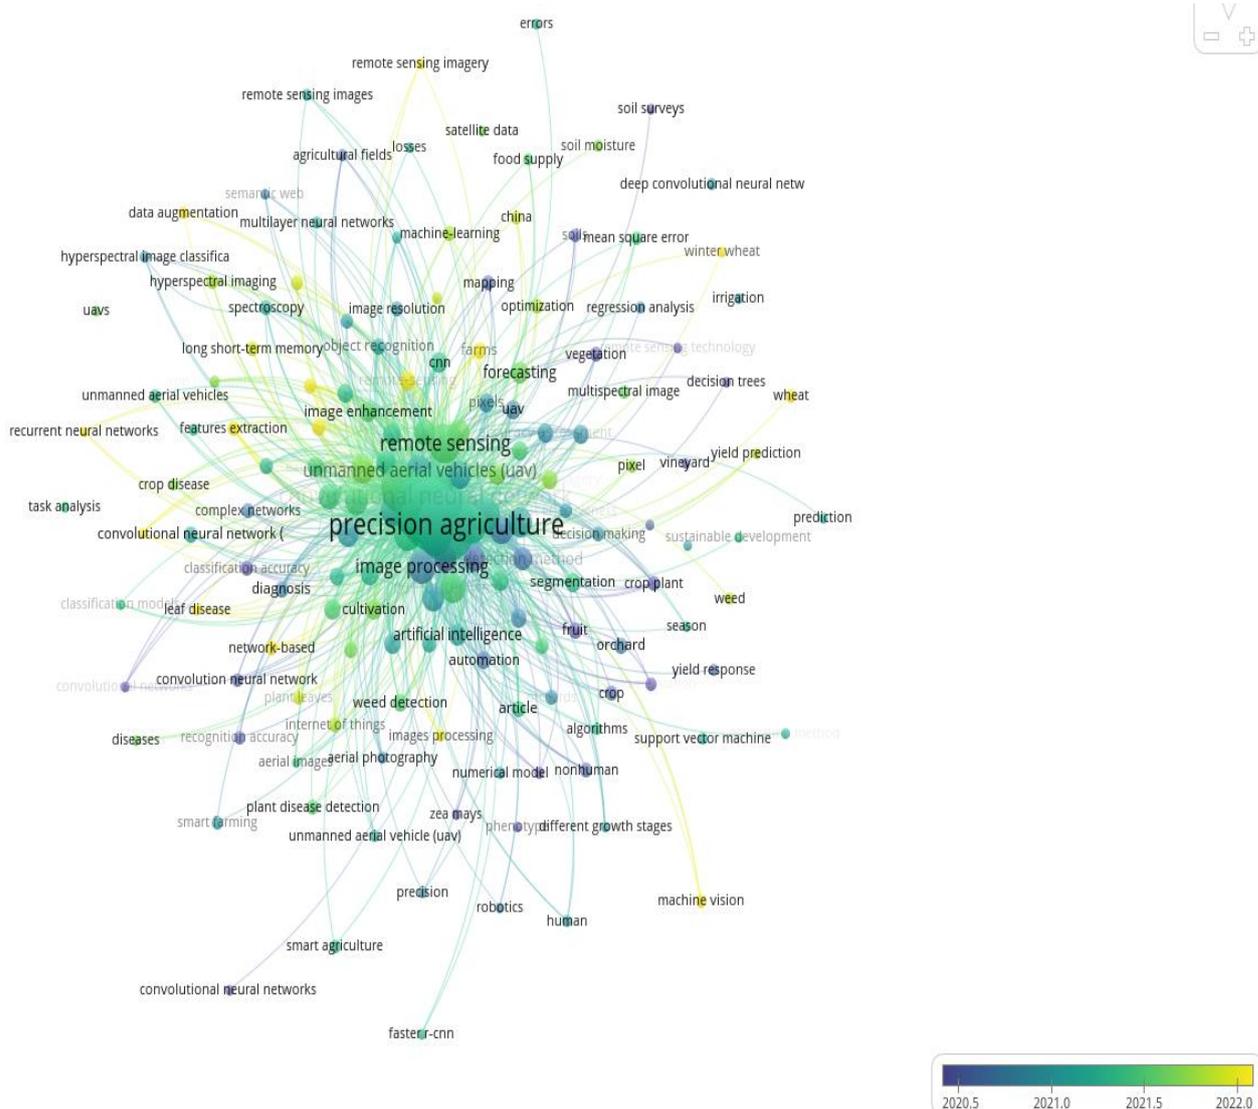
Figura 2 - Pesquisa inicial com termos de busca amplos



Fonte: (Autores, 2024).

Para a geração dos gráficos, foram consideradas somente palavras chaves que se encontram totalmente interconectadas nos documentos. A Figura 3, da base IEEE, é resultante de 127 palavras chaves. A Figura 4, correspondente à base Science Direct, considerou 268 palavras chaves. A Figura 5, da base Scopus, representa um estudo com o mínimo de 5 ocorrências de cada palavra-chave. Foi escolhido um mínimo maior do que as demais bases pela quantidade de informações disponibilizadas, afetando a visualização.

Figura 5 - Correlação de palavras chaves na base Scopus com no mínimo 5 ocorrências



Fonte: Autores, 2024.

Assim, observa-se nas Figuras 4 e 5 um destaque para o termo *precision agriculture*, inferindo a ampla abordagem do tema “agricultura de precisão”, o que não ocorre com os resultados da base IEEE. *Convolutional neural network* aparece com ênfase na base da Science Direct, não sendo tão destacado nas demais bases.

Esses resultados indicam que há uma maior concentração de trabalhos abordando os temas estudados na base Science Direct. No entanto, essa constatação necessita de uma análise mais detalhada dos documentos resultantes da busca.

3.3 Objetivos e definições das perguntas de pesquisa

Esta revisão sistemática da literatura tem por objetivo analisar estudos que tratam do tema de classificação de culturas, plantas daninhas e doenças, utilizando redes neurais artificiais do tipo redes neurais convolucionais. Assim, especificando o escopo dos resultados obtidos em relação aos objetivos deste trabalho, definiu-se as seguintes perguntas:

- Quais as principais arquiteturas de redes neurais artificiais utilizadas na literatura no reconhecimento de plantas?
- Quais as características das arquiteturas de redes neurais propostas pela literatura no reconhecimento de cultura e plantas daninhas?
- Quais são os parâmetros de avaliação utilizados pela literatura no reconhecimento de culturas e ervas daninhas?
- Quais são os desafios enfrentados para realizar o reconhecimento de cultura e plantas daninhas utilizando redes neurais artificiais?

3.4 Critérios de busca e seleção

A definição dos critérios de busca é crucial para estabelecer os objetivos da pesquisa. A seleção de estudos deve ser baseada em critérios pré-definidos, incluindo artigos que atendam a qualidade metodológica do estudo base. Isso garante a transparência e a qualidade dos estudos que serão analisados e servirão como norteadores para o desenvolvimento da nova pesquisa.

Dessa forma, este estudo baseou-se em seguir o método *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) para auxiliar nas definições de escolhas dos artigos. O método PRISMA se concentra na forma em que os autores realizam a completa análise sistemática e é dividido em quatro fases: identificação, triagem, elegibilidade e inclusão (Liberati *et al.*, 2009). O Quadro 1 apresenta as definições do método PRISMA para este trabalho.

Quadro 1 - Fase do método PRISMA

Identificação	Bases de dados: Science Direct, Scopus, ACM e IEEE Termos de busca utilizados: corn crops, weeds, convolutional neural networks, image processing String de busca: “corn crops” AND “weeds” AND “convolutional neural networks” AND “image processing” Período de busca: 2018 a 2023 Tipos de documentos: artigos e artigos de revisão
Triagem	Selecionar artigos com maior número de termos de busca juntos. Analisar a duplicidade dos artigos selecionados (se estão em mais de uma base de dados)
Elegibilidade	Analisar o título, palavras-chave e resumo dos artigos.
Inclusão	Análise dos artigos em relação ao tema de pesquisa.

Fonte: Adaptado de (Liberati *et al.*, 2009).

A fase de identificação busca estabelecer os parâmetros de busca e seleção dos artigos. Foram selecionadas as bases Science Direct, Scopus, ACM e IEEE, considerando os termos de busca *corn crops*, *weeds*, *convolutional neural networks*, *image processing*. A *string* de busca foi composta pelos termos conectados pelo operador AND. O período de busca estipulado em todas as bases foi de cinco anos (2018 até 2023). Por fim, os tipos de documentos foram artigos e artigos de revisão.

A triagem baseou-se em selecionar para análise os documentos resultantes da *string* de busca com os quatro termos escolhidos. Também buscou identificar artigos duplicados nas bases de dados.

A elegibilidade consistiu em analisar os documentos quanto às suas características com o objetivo deste trabalho, podendo incluí-lo ou excluí-lo do estudo. Assim, foram analisados título, palavras-chave e resumo.

Por fim, a fase de inclusão realizou a seleção dos artigos para serem considerados como base de estudo qualitativo. Assim, foi realizada uma análise aprofundada dos documentos selecionados.

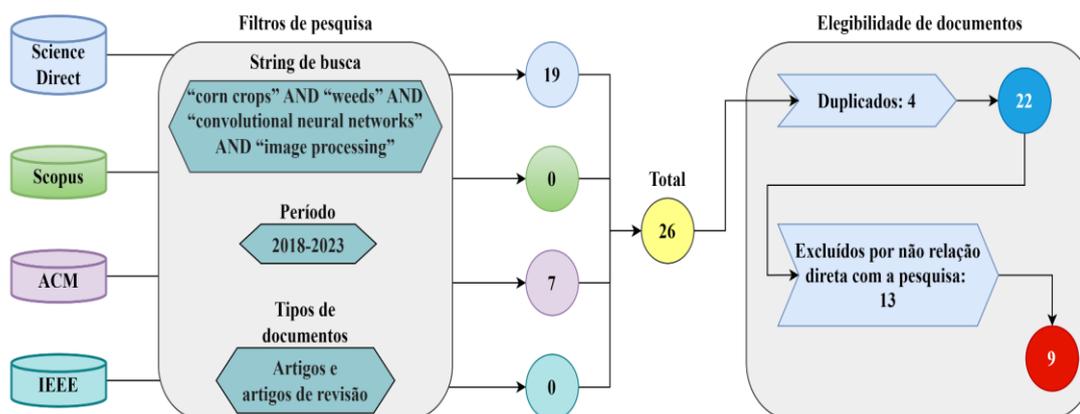
3.5 Seleção dos artigos para análise qualitativa

A busca com os termos específicos relacionados aos objetivos deste trabalho é apresentada pela Figura 6. A base Science Direct resultou em 19 documentos, ACM em 7, Scopus e IEEE com nenhuma. Assim, em um todo foram encontrados 26 artigos com os filtros estipulados.

Na parte de elegibilidade de documentos da Figura 6, são apresentados os critérios de análise que validaram a permanência ou não desses no estudo. Inicialmente, foram excluídos 4 artigos que se encontravam duplicados entre as bases. Após, foi realizada leitura dos títulos, palavras-chave e resumos dos 22 restantes. Com isso, 13 artigos foram removidos por não terem relação direta com esta pesquisa.

Por fim, restaram 9 artigos para análise. Estes artigos seguiram para um estudo mais aprofundado, visto que podem prover características importantes que impactam o desenvolvimento e estruturação desta pesquisa. Assim, a seção 3 apresenta os resultados individuais destes artigos.

Figura 6 - Artigos encontrados com os termos de busca específicos



Fonte: Autores, 2024.

4 RESULTADOS

A identificação das técnicas e métodos no desenvolvimento destes trabalhos é fundamental para definir o futuro de pesquisas nesta área. Assim, essa sessão busca abordar trabalhos equívocos ao objetivo desta pesquisa, cujo tratem do tema de

análise de imagens para a identificação de pragas em lavouras ou plantas, com base nos resultados qualitativos previamente descritos.

4.1 Trabalhos identificados com a temática da pesquisa

Considerando o propósito de classificar ou identificar padrões em culturas, foram detalhados os nove estudos resultantes das etapas anteriores. Para isso, foi elaborado um quadro comparativo destes trabalhos, Quadro 2, contendo os objetivos, métodos ou/e arquiteturas de redes neurais convolucionais utilizadas, origem dos dados utilizados, quantidade de imagens e o desempenho obtido pelos métodos utilizados

Por fim, os artigos foram descritos, contendo as principais características destacadas pelos autores. Com isso, é possível analisar e identificar recursos que impactaram nas métricas destes estudos, para que, posteriormente, sejam avaliados na solução do problema desta pesquisa.

Quadro 2 - Trabalhos identificados com a temática da pesquisa

Artigo	Objetivo	Métodos / arquiteturas	Origem dos dados	Quantidade de imagens	Desempenho
Chen <i>et al.</i> (2021)	Classificar doenças na cultura do arroz, milho e pepino	MobileNet-V2, MobileNet-V1, NASNetMobile, EfficientNet-B0 e DenseNet-121	Imagens de milho e arroz foram capturadas. As de pepino são da internet	500 imagens de arroz, 466 de milho e 80 de pepino	Acurácia de 99.71% para a MobileNet-V2 (modelo proposto)
Divyanth, Ahmad e Saraswat (2022)	Identificar e segmentar doenças do milho	SegNet, UNet, and DeepLabV3+	Capturadas especificamente para o desenvolvimento do trabalho	1.050 imagens capturadas para o trabalho	Intersecção média ponderada sobre união de 0.9422 para UNet na segmentação das folhas e 0.7379 para DeepLabv3+ na segmentação de lesões
Haichen, Qingrui, Guang (2021)	Classificar plantas daninhas e plantação	VGG16+SVM	Capturadas e preparadas exclusivamente para o trabalho (lavoura)	4.245 imagens: milho, trigo e beterraba; + 9 tipos de plantas daninhas	Acurácia de 96.4%
Pandey e Jain (2022)	Classificar culturas e plantas daninhas (arroz, cana, feijão, trigo e capim elefante))	CD-CNN, RF-200, SVM, AlexNet, VGG-16, VGG-19 and ResNet-50	Capturadas por drone especificamente para o trabalho	2.000 imagens de cada cultura	Acurácia de 96.2% da CD-CNN, melhor resultado quando comparado as demais arquiteturas
Picon <i>et al.</i> (2022)	Classificar milho e espécies de plantas daninhas	PSPNet (Pyramid Scene Parsing Network)	Imagens capturadas para o desenvolvimento do trabalho, contendo milho, plantas daninhas gramíneas e plantas daninhas de folha larga	11.742 imagens organizadas em 3 bases.	Coefficiente de Dice-Sørensen de 47.97

Quadro 2 - Trabalhos identificados com a temática da pesquisa

Artigo	Objetivo	Métodos / arquiteturas	Origem dos dados	Quantidade de imagens	Desempenho
Suh <i>et al.</i> (2018)	Estudar as redes neurais convolucionais quanto ao reconhecimento de plantas daninhas	VGG16 e ResNet (10, 14, 18, 34, 50)	Capturadas e preparadas exclusivamente para o trabalho (lavoura)	5.326 imagens de Trevo, Dente-de-leão, Grama, erva de passarinho e Speedwell delgado	O tamanho da imagem afeta a acurácia do classificador. O “corte” de camadas convolucionais pode não impactar significativamente na classificação das imagens.
Sunil <i>et al.</i> (2022)	Classificar ervas daninhas e plantação	VGG16+SVM	Capturadas e preparadas exclusivamente para o trabalho (potes)	3.792 de culturas e plantas daninhas.	VGG16 superou os resultados da SVM. F1-score médios entre 93% e 97.5%
Veeragandham e Santhi (2022)	Classificar ervas e amendoim e amendoim Classificar milho e amendoim	AlexNet, VGG16, VGG19, ResNet50 e ResNet101	Base de amendoim de capturada para o trabalho. Base de milho	24.816 de amendoim e 5998 de milho e ervas	Acurácia de 99.84% para a base de amendoim. 100% para a base de milho
Wessner <i>et al.</i> (2023)	Classificar milho e plantas daninhas	MobileNet v2, MobileNet V2 Adaptada e Inception V3	Imagens capturadas e organizadas especificamente para o trabalho	27.523 imagens capturadas	Acurácia de 98% para InceptionV3

Fonte: Autores, 2024.

O artigo de Chen *et al.* (2021), teve por objetivo realizar a classificação de doenças nas culturas do milho, arroz e pepino. Cerca de 1.000 imagens de cenários reais, classificadas conforme a cultura e doença, foram utilizadas. A arquitetura de rede neural convolucional MobileNet-V2 foi utilizada no processo de classificação, juntamente com o módulo de Atenção Suave de Localização. Segundo os autores,

essa arquitetura tem desempenho consideravelmente bom quando considerada a quantidade de parâmetros gerados, o que deve ser avaliado em casos de baixa capacidade computacional. Foi utilizada também, uma estratégia de visualização localizada, informando regiões significativas nas imagens. A fim de melhorar o desempenho do modelo, a função de perda foi otimizada em uma abordagem progressiva de duas fases, inicialmente focado em recursos mais gerais e, em seguida, nos detalhes mais específicos. Também, a utilização de um modelo pré-treinado foi construída para a melhoria de desempenho. Para comparar os resultados, as redes MobileNet-V1, NASNetMobile, EfficientNet-B0 e DenseNet-121 também foram treinadas. Por fim, os pesos do treinamento da arquitetura MobileNet-V2 foram escolhidos como de melhor desempenho, resultando em uma acurácia média de 99,13% na identificação de doenças nas culturas propostas.

Divyanth, Ahmad e Saraswat (2022), desenvolveram uma pesquisa abordando a necessidade de segmentar as folhas de milho de imagens com fundos complexos, classificar doenças e segmentar a região de interesse. Para isso, foram capturadas 1.050 imagens da cultura, sobre diferentes condições climáticas. Para o treinamento, foram utilizadas as arquiteturas de redes neurais convolucionais SegNet, UNet e DeepLabV3+. Nas definições de parâmetros para treinar os modelos, considerando o problema do paradoxo da precisão, uma proporção ótima de peso com base na frequência mediana das classes foi definida como um hiperparâmetro adicional na tarefa de segmentação de lesões. Como resultados, a arquitetura UNet teve melhor desempenho na segmentação de folhas de milho, com mwIoU 0.9422, mBFScore de 0.8063 e DSC de 0.7758. Na tarefa de segmentação de lesões das doenças, a DeepLabv3+ obteve mwIoU de 0.7379, mBFScore de 0.5351 e DSC de 0.5731. Quanto à identificação das doenças, a DeepLabv3+ também obteve os melhores resultados com acurácia de 62.75% e IoU de 0.6357.

Haichen, Qingrui, Guang (2021), buscaram analisar formas de classificar imagens de milho, trigo e beterraba; + 9 tipos de espécies de plantas daninhas. Para isso, 4.245 imagens foram capturadas de diferentes estágios de crescimento para serem utilizadas neste trabalho. Para o modelo de classificação, foi utilizada a arquitetura VGG16. Também, utilizaram o SVM (Máquinas de Vetores de Suporte Linear) adicionada à rede neural como substitutivo da função *Softmax*, a fim de incrementar a acurácia do modelo. Foi definida uma etapa de pré-processamento das imagens (escala cinza, binarização, remoção de impurezas, filtragem Gaussiana e

sobreposição da imagem de saída). Como resultado, o otimizador Adam, quando comparado com o AdaGrad e RMSProp, obteve um resultado melhor. Os tamanhos de lote (*batch size*) de 16 e 32 obtiveram melhores resultados, quando em comparação com o de 64. O Dropout de melhor desempenho foi o 0.1, quando comparado com 0.3, 0.5 e 0.9. Por fim, a acurácia do modelo treinado obteve um resultado de 96.4%.

Pandey e Jain (2022) abordaram como tema de pesquisa a classificação de culturas (arroz, cana, feijão, trigo e capim elefante) e plantas daninhas. A base de dados utilizada foi estruturada por 2.000 imagens de cada tipo de cultura, capturada de lavouras por um *drone*. Para o sistema de classificação, foi utilizada a arquitetura de rede neural convolucional Densa Conjugada (CD-CNN) com uma nova função de ativação chamada de SL-ReLU. Essa função permite a classificação inteligente de múltiplas culturas através de imagens RGB. Para comparar os resultados deste modelo neural proposto, foram utilizadas para comparar os resultados as técnicas de aprendizado de máquina SVM e RF-200 e as arquiteturas de redes neurais convolucionais AlexNet, VGG-16, VGG-19 e ResNet-50. No entanto, a arquitetura proposta CD-CNN obteve os melhores resultados, atingindo uma acurácia de 96.2%.

Picon *et al.* (2022) propuseram um modelo de aprendizado de máquina profundo para segmentar e distinguir plantas de milho e diferentes espécies de ervas daninhas. Para isso, foram organizadas três bases de dados. A primeira foi composta unicamente por plantas de milho, a segunda por ervas daninhas de folhas estreitas e a terceira por plantas daninhas de folha larga. Na etapa de segmentação e classificação, foi proposta a arquitetura Dual PSPNet. Esse modelo permite realizar a segmentação e a classificação de forma simultânea no processo. Nos resultados, foram avaliadas combinações entre as bases de dados para o treinamento. O melhor resultado obtido foi o Coeficiente de Dice-Sørensen de 47.97, considerando a combinação de imagens reais e de classes de plantas únicas no treinamento.

Suh *et al.* (2018) estudaram a versatilidade das CNNs quanto ao reconhecimento de plantas daninhas. As imagens utilizadas no trabalho foram exclusivamente capturadas para o treinamento dos modelos neurais propostos, foram 5.326 imagens de Trevo, Dente-de-leão, Grama, Erva-de-passarinho e Speedwell Delgado. As arquiteturas de rede neurais utilizadas nos testes foram a VGG16 (derivações desta arquitetura foram utilizadas) e ResNet (10, 14, 18, 34, 50). Na avaliação, duas arquiteturas derivadas da ResNet e quatro da VGG16 foram

configuradas para avaliar a classificação considerando o menor número de camadas convolucionais. Nos modelos ResNet testados, resultados consideráveis foram encontrados, concluindo que a profundidade do modelo não é benéfica para a classificação. A VGG16 indicou que a redução no número de camadas convolucionais em até quatro retém uma precisão consideravelmente boa. Também, a existência de max-pooling na configuração pode melhorar o desempenho, mas não de forma substancial. Por fim, um teste sobre o tamanho da imagem de treinamento foi realizado, concluindo que quanto menor a resolução da imagem, menor também será a acurácia do classificador.

Sunil *et al.* (2022) tiveram por objetivo classificar culturas e plantas daninhas, comparando a utilização do aprendizado de máquina com Support Vector Machine (SVM) e aprendizado profundo de máquina com VGG16. Foram 3.792 imagens, 2.271 compostas de quatro tipos de plantas daninhas e 1.521 de seis tipos de culturas. Na implementação do SVM, foram realizadas as etapas de pré-processamento e extração de características das imagens. Na parte de seleção de características, a ênfase foi na aplicação do algoritmo Relief-F, pela habilidade de diferenciar classes e por ser comumente utilizado. No teste utilizando a arquitetura VGG16, a técnica de transferência de aprendizado foi utilizada, bem como o congelamento de algumas camadas de convolução e pooling, a fim de melhorar o desempenho de treinamento do modelo. Também, cada classe de cultura foi treinada individualmente com as classes de plantas daninhas. Por fim, os resultados atingidos pela arquitetura VGG16 superou os resultados do SVM. Os resultados médios de f1-score para esse modelo permaneceram entre 93% e 97,5%. Foi destacado que para o treinamento da classe de milho e plantas daninhas foi atingido um resultado de f1-score de 100%.

Veeragandham e Santhi, 2022 realizam a pesquisa com a necessidade de classificar culturas e plantas daninhas. Para isso, duas bases de dados foram utilizadas, uma de 24.816 de amendoim e ervas - desenvolvida pelos autores para este trabalho, e outra com 5.998 de milho e ervas daninhas. As arquiteturas de redes neurais utilizadas foram: AlexNet, VGG16, VGG19, ResNet50 e ResNet101. Na etapa de treinamento das arquiteturas neurais, foram realizadas comparações entre utilizar ou não no modelo a técnica de transferência de aprendizado. De forma geral, a acurácia aumentou de 90.10% para 99.54% para a base de imagens de amendoim e de 94.66% para 99.83% no de milho. Os autores observaram que a VGG19 obteve um maior ganho de acurácia com a implantação dessa técnica. Por fim, os autores

constatarem que a ResNet-50 obteve o melhor resultado para a base de amendoim, com 99.84% de acurácia, e ResNet-101 e VGG-16 as melhores para a base de milho, com 100%.

Wessner *et al.* (2022) desenvolveram uma pesquisa com o objetivo de classificar milho e plantas daninhas. As imagens capturadas de lavouras de milho em diferentes estágios de crescimento, especialmente para o trabalho, formaram uma base com 27.523. As arquiteturas neurais utilizadas foram a MobileNet-V2, MobileNet-V2 Adaptada e Inception-V3. Este trabalho considerou em não realizar distinções entre plantas daninhas, tratando-as como uma classe unificada no processo de classificação das redes neurais. As características fisiológicas, bem como a composição de objetos das imagens, formaram as classes de saídas das arquiteturas neurais. Assim, os resultados obtidos variaram de 84% a 90% na classificação. Considerando o objetivo proposto de realizar a distinção entre milho e plantas daninhas, a melhor acurácia foi de 98%.

4.2 Correlação entre palavras-chave

Considerando os dados encontrados nos documentos, é possível desenvolver algumas correlações entre as palavras-chave. Dessa maneira, utilizando a ferramenta de construção e visualização de redes bibliografia, *VosViewer*, gerou-se algumas considerações dos resultados.

A Figura 7 apresenta a rede de palavras-chave dos nove documentos em análise. Na horizontal, observa-se a conexão entre os termos *deep learning*, *convolutional neural network* e *image classification*. Isso demonstra a aplicação de problemas de classificação de imagens sendo desenvolvidas com o uso dessas duas áreas da Inteligência Artificial, aprendizado profundo e redes neurais convolucionais.

Ligado diretamente à classificação de imagens, temas como *crop disease recognition*, *weed* e *crop identification*, sequencialmente doenças de culturas, ervas daninhas e identificação de culturas, são foco dos trabalhos.

Já em redes neurais convolucionais, a rede é formada com termos como *weed*, *corn*, *agriculture*, *multi-weed classification* e *weed semantic segmentation*, sequencialmente, plantas daninhas, milho, agricultura, classificação de múltiplas plantas daninhas e segmentação semântica de plantas daninhas. Nesse caso, observa-se que a aplicação de técnicas de redes neurais começa a focar no problema

deep learning e a classificação de imagens conecta-se com redes neurais convolucionais.

As aplicações são diretamente interligadas nos documentos com o tema de aprendizado profundo e suas generalizações com o tema de redes neurais convolucionais.

Figura 8 - Correlação de palavras-chave com pelo menos 2 ocorrências

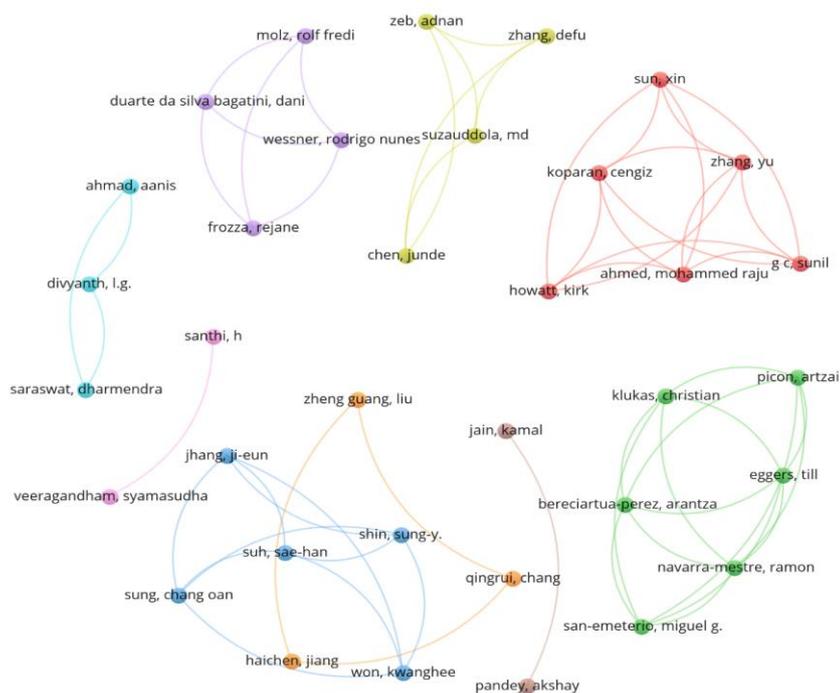


Fonte: Autores, 2024.

4.3 Correlação entre autores

A fim de verificar a compatibilidade de pesquisa entre os autores dos nove artigos selecionados para o estudo, gerou-se a Figura 9.

Figura 9 - Correlação entre os autores



Fonte: Autores, 2024.

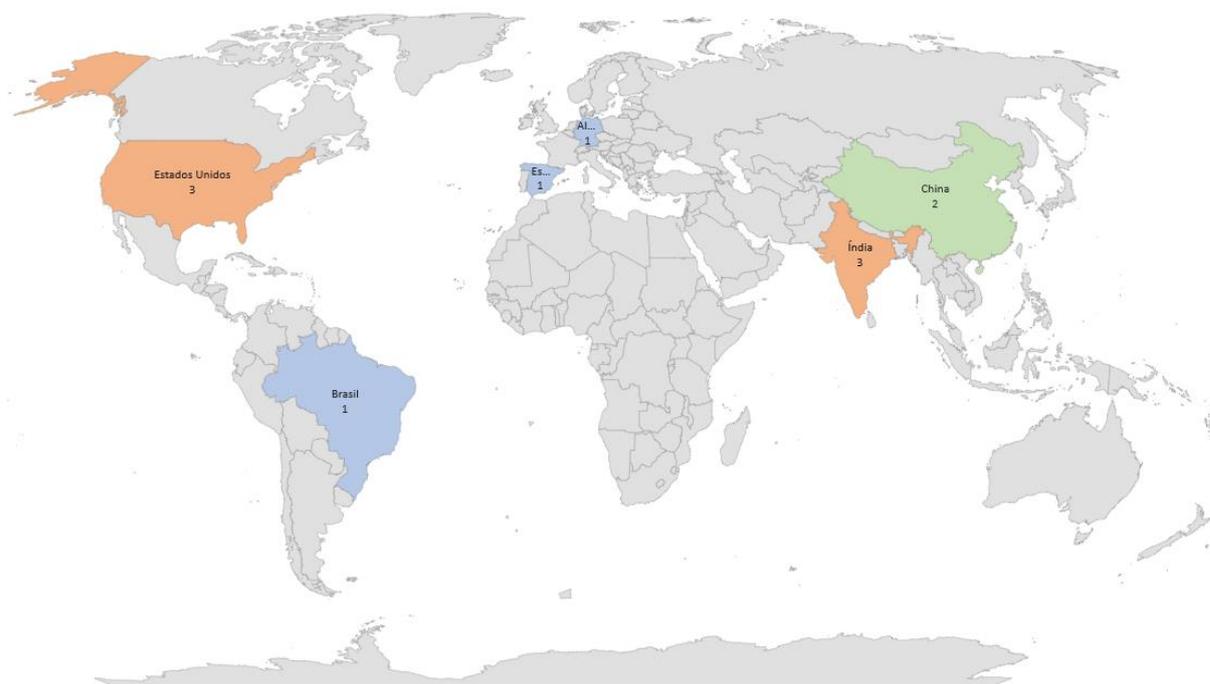
É possível identificar que não há integração dos autores entre as pesquisas. A ilustração com os nove *clusters* é *isolada*, indicando a ausência de cooperação no desenvolvimento das pesquisas

Essa indicação pode ser um fator de impacto no avanço dos temas em questão. A falta de comunicação e compartilhamento de trabalhos pode atrasar a implementação e a aplicação de produtos e técnicas.

4.4 Locais dos desenvolvimentos das pesquisas

Buscou-se entender os locais nos quais estão ocorrendo as pesquisas em análise. Dessa forma, por meio das informações das universidades dos autores, foram mapeados, na Figura 10, os países das pesquisas.

Figura 10 - Localização das pesquisas



Fonte: Autores, 2024.

Estados Unidos e Índia contemplam a maior quantidade de autores dos trabalhos, com 3 cada. China contempla 2, e Brasil, Espanha e Alemanha com 1 desenvolvimento cada.

5 CONCLUSÃO

A partir da realização desta revisão sistemática da literatura, foi possível validar que a utilização de tecnologias da informação está sendo amplamente aprimorada para solucionar o problema do controle de pragas em diversas culturas. As técnicas baseadas em redes neurais convolucionais têm se mostrado eficazes e promissoras para enfrentar esse desafio. No entanto, é importante ressaltar que a influência e as características das arquiteturas utilizadas têm um impacto subjetivo nos resultados, sendo também dependentes de cada abordagem de desenvolvimento.

Este estudo permitiu identificar a interconexão entre temas e autores, possibilitando avaliar não apenas as técnicas aplicadas no objetivo central desta pesquisa, mas também ampliar a fonte de conhecimento. Observa-se que a identificação de plantas daninhas, pragas e doenças parte de conceitos e técnicas equivalentes, porém, os resultados variam de acordo com as características específicas de cada implementação. Devido à complexidade dos modelos neurais empregados, cada detalhe de implementação pode influenciar subjetivamente o desfecho da solução.

O trabalho de Chen *et al.* (2021) abordou doenças em diversas culturas, incluindo o milho, e os autores destacaram a obtenção de resultados excelentes, despertando interesse pelas técnicas utilizadas, que podem ser avaliadas em outros cenários, como a classificação de pragas biológicas. Da mesma forma, o estudo de Divyanth, Ahmad e Saraswat (2022) analisou os resultados com o uso de técnicas de mensuração menos comuns na literatura, sugerindo que diferentes métodos de avaliação estão disponíveis.

O avanço do processamento de imagens em tempo real é fundamental devido à necessidade de detecção rápida e precisa de pragas agrícolas. Além disso, a utilização de equipamentos em movimento sobre a cultura para esse controle requer tomadas de decisão ágeis e precisas.

Os resultados obtidos nesta pesquisa contribuirão para o desenvolvimento de um modelo inteligente de identificação de plantas daninhas em lavouras de milho. As características dos estudos encontrados, como capacidade de processamento e reconhecimento das plantas, servirão de base para aprimorar e expandir futuras investigações.

Em relação aos problemas de pesquisa definidos, apresenta-se a seguir a resposta a cada um.

i) Quais as principais arquiteturas de redes neurais artificiais utilizadas na literatura no reconhecimento de plantas?

A partir dos trabalhos selecionados para a análise, observou-se que algumas arquiteturas de redes neurais convolucionais são amplamente utilizadas. Modelos baseados em arquiteturas como VGG, MobileNet, DenseNet e ResNet foram utilizados, atingindo bons resultados no geral, conforme descrito pelos autores.

ii) Quais as características das arquiteturas de redes neurais propostas pela literatura no reconhecimento de cultura e plantas daninhas?

As arquiteturas de redes neurais aplicadas nas pesquisas analisadas basearam-se em modelos já estruturados, como a VGG, MobileNet, DenseNet, ResNet e outras. No entanto, existem possibilidades de configurá-las conforme a necessidade, o que possibilita aplicar e avaliar o desempenho de cada uma com base no objetivo proposto.

iii) Quais são os parâmetros de avaliação utilizados pela literatura no reconhecimento de culturas e ervas daninhas?

Observou-se que as métricas de avaliação dos modelos neurais utilizados no reconhecimento de plantas são dependentes da escolha individual de cada pesquisa e que não existe um padrão. As principais utilizadas são a acurácia e a F1-score. No entanto, o motivo de escolha pode estar ligado diretamente à necessidade em que se deseja comprovar nos resultados. Sunil *et al.* (2022), abordam a importância da escolha da métrica certa, com base em que se objetiva comprovar, lembrando que um erro nessa escolha pode gerar engano no momento da aplicação.

iv) Quais são os desafios enfrentados para realizar o reconhecimento de cultura e plantas daninhas utilizando redes neurais artificiais?

A implementação de um modelo neural capaz de realizar o reconhecimento de padrões é complexo e computacionalmente custoso em processamento. São muitos os parâmetros a serem equilibrados, de forma que possibilitem explorar ao máximo a capacidade da arquitetura. Por outro lado, observa-se nos trabalhos relacionados ao tema da pesquisa, o quanto é importante a qualidade dos dados de entrada. Esses

devem ser previamente bem tratados e rotulados, possibilitando uma clareza de padrão entre as classes, o que permite a arquitetura neural identificar e melhorar seu aprendizado. Também, uma característica do aprendizado supervisionado de máquina é a quantidade expressa de dados para realizar o aprendizado pelo modelo. As arquiteturas necessitam de uma quantidade ideal de dados, que caracterizam o mais próximo possível o cenário da aplicação em questão.

REFERÊNCIAS

CHEN, J.; ZHANG, D.; SUZAUDDOLA, M.; ZEB, A. Identifying crop diseases using attention embedded MobileNet-V2 model. **Applied Soft Computing**, v. 113, p. 107901, 2021. Disponível em: <https://doi.org/10.1016/j.asoc.2021.107901>.

COULIBALY, S.; KAMUSU-FOGUEM, B.; KAMISSOKO, D.; TRAORE, D. Deep learning for precision agriculture: A bibliometric analysis. **Intelligent Systems with Applications**, v. 16, p. 200102, 2022. Disponível em: <https://doi.org/10.1016/j.iswa.2022.200102>.

DIVYANTH, L. G.; AHMAD, A.; SARASWAT, D. A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery. **Smart Agricultural Technology**, v. 3, p. 100108, 2023. Disponível em: <https://doi.org/10.1016/j.atech.2022.100108>.

FAN, X.; CHAI, X.; ZHOU, J.; SUN, T. Deep learning based weed detection and target spraying robot system at seedling stage of cotton field. **Computers and Electronics in Agriculture**, v. 214, p. 108317, 2023. Disponível em: <https://doi.org/10.1016/j.compag.2023.108317>.

FERREIRA, A. S.; FREITAS, D. M.; DA SILVA, G. G.; PISTORI, H.; FOLHES, M. T. Weed detection in soybean crops using ConvNets. **Computers and Electronics in Agriculture**, v. 143, p. 314-324, 2017. Disponível em: <https://doi.org/10.1016/j.compag.2017.10.027>.

GARIBALDI-MÁRQUEZ, F.; FLORES, G.; MERCADO-RAVELL, D. A.; RAMÍREZ-PEDRAZA, A.; VALENTÍN-CORONADO, L. M. Weed Classification from Natural Corn Field-Multi-Plant Images Based on Shallow and Deep Learning. **Sensors**, v. 22, n. 3021, 2022. Disponível em: <https://doi.org/10.3390/s22083021>.

HAICHEN, J.; QINGRUI, C.; GUANG, L. Z. Weeds and Crops Classification Using Deep Convolutional Neural Network. *In: Proceedings of the 3rd International Conference on Control and Computer Vision (ICCCV '20)*. New York, NY, USA: Association for Computing Machinery, 2021. p. 40–44. Disponível em: <https://doi.org/10.1145/3425577.3425585>.

HAQ, M. A. CNN Based Automated Weed Detection System Using UAV Imagery. **Computer Systems Science & Engineering**, v. 42, n. 2, 2021. Disponível em: <https://doi.org/10.32604/csse.2022.023016>.

HAYKIN, S. **Neural Networks and Learning Machines**. 3 ed. Pearson Education, 2009.

KLOMPENBURGA, T. V.; KASSAHUNA, A.; CATAL, C. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105709>.

CHEN, J.; ZHANG, D.; SUZAUDDOLA, M.; ZEB, A. Identifying crop diseases using attention embedded MobileNet-V2 model. **Applied Soft Computing**, v. 113, p. 107901, 2021. Disponível em: <https://doi.org/10.1016/j.asoc.2021.107901>.

COULIBALY, S.; KAMSU-FOGUEM, B.; KAMISSOKO, D.; TRAORE, D. Deep learning for precision agriculture: A bibliometric analysis. **Intelligent Systems with Applications**, v. 16, p. 200102, 2022. Disponível em: <https://doi.org/10.1016/j.iswa.2022.200102>.

DIVYANTH, L. G.; AHMAD, A.; SARASWAT, D. A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery. **Smart Agricultural Technology**, v. 3, p. 100108, 2023. Disponível em: <https://doi.org/10.1016/j.atech.2022.100108>.

FAN, X.; CHAI, X.; ZHOU, J.; SUN, T. Deep learning based weed detection and target spraying robot system at seedling stage of cotton field. **Computers and Electronics in Agriculture**, v. 214, p. 108317, 2023. Disponível em: <https://doi.org/10.1016/j.compag.2023.108317>.

FERREIRA, A. S.; FREITAS, D. M.; DA SILVA, G. G.; PISTORI, H.; FOLHES, M. T. Weed detection in soybean crops using ConvNets. **Computers and Electronics in Agriculture**, v. 143, p. 314-324, 2017. Disponível em: <https://doi.org/10.1016/j.compag.2017.10.027>.

GARIBALDI-MÁRQUEZ, F.; FLORES, G.; MERCADO-RAVELL, D. A.; RAMÍREZ-PEDRAZA, A.; VALENTÍN-CORONADO, L. M. Weed Classification from Natural Corn Field-Multi-Plant Images Based on Shallow and Deep Learning. **Sensors**, v. 22, n. 3021, 2022. Disponível em: <https://doi.org/10.3390/s22083021>.

HAICHEN, J.; QINGRUI, C.; GUANG, L. Z. Weeds and Crops Classification Using Deep Convolutional Neural Network. *In: Proceedings of the 3rd International Conference on Control and Computer Vision (ICCCV '20)*. New York, NY, USA: Association for Computing Machinery, 2021. p. 40–44. Disponível em: <https://doi.org/10.1145/3425577.3425585>.

HAQ, M. A. CNN Based Automated Weed Detection System Using UAV Imagery. **Computer Systems Science & Engineering**, v. 42, n. 2, 2021. Disponível em: <https://doi.org/10.32604/csse.2022.023016>.

HAYKIN, S. **Neural Networks and Learning Machines**. 3 ed. Pearson Education, 2009.

KLOMPENBURGA, T. V.; KASSAHUNA, A.; CATAL, C. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105709>.

LIBERATI, A.; ALTMAN, D. G.; TETZLAFF, J.; MULROW, C.; GÖTZSCHE, P. C.; IOANNIDIS, J. P.; CLARKE, M.; DEVEREAUX, P. J.; KLEIJNEN, J.; MOHER, D. The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. **PLoS Med.**, v. 6, n. 7, p. e1000100, 2009. DOI: <https://doi.org/10.1371/journal.pmed.1000100>.

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. Disponível em: <https://doi.org/10.1016/j.compag.2020.105760>.

PANDEY, A.; JAIN, K. An intelligent system for crop identification and classification from UAV images using conjugated dense convolutional neural network. **Computers and Electronics in Agriculture**, v. 192, p. 106543, 2022. Disponível em: <https://doi.org/10.1016/j.compag.2021.106543>.

PETERSEN, K.; FELDT, R.; MUJTABA, S.; MATTSSON, M. Systematic mapping studies in software engineering. *In: Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering (EASE'08)*. Swindon, GBR: BCS Learning & Development Ltd., 2008. p. 68–77.

PICON, A.; SAN-EMETERIO, M. G.; BERECIARTUA-PEREZ, A.; KLUKAS, C.; EGGERS, T.; NAVARRA-MESTRE, R. Deep learning-based segmentation of multiple species of weeds and corn crop using synthetic and real image datasets. **Computers and Electronics in Agriculture**, v. 194, p. 106719, 2022. Disponível em: <https://doi.org/10.1016/j.compag.2022.106719>.

SANTOS, E. S.; SANTOS, J. D.; VOGADO, L. H. S.; SOUSA, L. P.; SOARES, H. A.; VERAS, R. M. S. Explicando as decisões com IAs: Demonstrando sua aplicação em imagens médicas. *In: XXIII SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE - SBCAS 2023*.

SCODRO, L.; CORSO, L. L. Previsão de preço de alimentos utilizando o método ARIMA e Inteligência Artificial. **Revista Produção Online**, v. 23, n. 1, e-4869, 2023. Florianópolis.

SCHÜLER, S.; KIPPER, L. M.; MORAES, J. A. R.; ITURBITE, J. M. P.; LOBO, E. A. Inovação e sustentabilidade na agricultura do continente africano: uma revisão bibliométrica. **Revista Produção Online**, v. 23, n. 2, e-4910, 2023. Florianópolis.

SHAFI, U.; MUMTAZ, R.; GARCÍA-NIETO, J.; HASSAN, S. A.; ZAIDI, S. A. R.; IQBAL, N. Precision Agriculture Techniques and Practices: From Considerations to Applications. **Sensors**, v. 19, n. 3796, 2019. Disponível em: <https://doi.org/10.3390/s19173796>

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. Applications of Remote Sensing in Precision Agriculture: A Review. **Remote Sens.**, v. 12, p. 3136, 2020. Disponível em: <https://doi.org/10.3390/rs12193136>.

SOUZA, V.; ARAÚJO, L.; SILVA, L.; SANTOS, A. Análise comparativa de redes neurais convolucionais no reconhecimento de cenas. *In*: XI COMPUTER ON THE BEACH, Balneário Camburiú, SC, 2020. Disponível em: <https://doi.org/10.14210/cotb.v11n1.p419-426>.

SUBEESH, A.; BHOLE, S.; SINGH, K.; CHANDEL, N. S.; RAJWADE, Y. A.; RAO, K. V. R.; KUMAR, S. P.; JAT, D. Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. **Artificial Intelligence in Agriculture**, v. 6, p. 47-54, 2022. ISSN 2589-7217. Disponível em: <https://doi.org/10.1016/j.aiia.2022.01.002>.

SUH, S.; JHANG, J.; WON, K.; SHIN, S.; SUNG, C. O. Development of vegetation mapping with deep convolutional neural network. *In*: PROCEEDINGS OF THE 2018 CONFERENCE ON RESEARCH IN ADAPTIVE AND CONVERGENT SYSTEMS (RACS '18). New York, NY, USA: Association for Computing Machinery, 2018. p. 53–58. Disponível em: <https://doi.org/10.1145/3264746.3264753>

SUNIL G. C.; ZHANG, Y.; KOPARAN, C.; AHMED, M. R.; HOWATT, K.; SUN, X. Weed and crop species classification using computer vision and deep learning technologies in greenhouse conditions. **Journal of Agriculture and Food Research**, v. 9, 100325, 2022. ISSN 2666-1543. Disponível em: <https://doi.org/10.1016/j.jafr.2022.100325>.

VEERAGANDHAM, S.; SANTHI, H. Effectiveness of convolutional layers in pre-trained models for classifying common weeds in groundnut and corn crops. **Computers and Electrical Engineering**, v. 103, 108315, 2022. Disponível em: <https://doi.org/10.1016/j.compeleceng.2022.108315>.

WESSNER, R. N.; FROZZA, R.; BAGATINI, D. D. S.; MOLZ, R. F. Recognition of weeds in corn crops: System with convolutional neural networks. **Journal of Agriculture and Food Research**, v. 14, 100669, 2023. Disponível em: <https://doi.org/10.1016/j.jafr.2023.100669>.

AUTORES

Rodrigo Nunes Wessner

Mestrando em Sistemas e Processos Industriais e graduado em Ciência da Computação pela Universidade de Santa Cruz do Sul. Desenvolvedor de software com atuação em sistemas bancários e agricultor. Pesquisa temas relacionados à Inteligência Artificial (Redes Neurais Artificiais, Aprendizado de Máquina).

Rejane Frozza

Doutora em Computação pela Universidade Federal do Rio Grande do Sul (UFRGS-RS), com estágio doutoral sanduíche na Université Joseph Fourier (Grenoble-France). Professora adjunta da Universidade de Santa Cruz do Sul (UNISC-RS), no Departamento de

Engenharias, Arquitetura e Computação, no Programa de Pós-Graduação em Sistemas e Processos Industriais - Mestrado e no Programa de Pós-Graduação em Letras - Mestrado e Doutorado. Pesquisa temas relacionados à Inteligência Artificial (Agentes Conversacionais, Agentes Pedagógicos em Sistemas Virtuais de Aprendizagem, Gestão do Conhecimento, Sistemas Multiagentes, Redes Neurais Artificiais, Sistemas Difusos, Sistemas de Raciocínio Baseado em Casos, Aprendizado de Máquina).

Rolf Fredi Molz

Doutor em Computação pela Universidade Federal do Rio Grande do Sul (UFRGS-RS). Professor titular da Universidade de Santa Cruz do Sul (UNISC-RS) e Pró-Reitor Acadêmico da mesma IES. Avaliador de cursos e instituições de Ensino Superior junto ao Instituto Nacional de Estudos e Pesquisas Educacionais (INEP) - Ministério da Educação; avaliador para acreditação de cursos de Engenharia para o Mercosul, sócio e engenheiro responsável na empresa ImPLY Tecnologia Eletrônica Ltda. Pesquisa temas relacionados à Arquitetura de Sistemas de Computação (Processamento de Imagens, Redes Neurais).



Artigo recebido em: 18/04/2024 e aceito para publicação em: 25/05/2024

DOI: <https://doi.org/10.14488/1676-1901.v24i2.5249>