

# O USO DE INTELIGÊNCIA ARTIFICIAL NO MANEJO INTEGRADO DE DOENÇAS DE PLANTAS

Felipe Barboza de Oliveira<sup>1</sup>  
Eloíza Martins Primo Capeloci<sup>2</sup>

## RESUMO

A implementação da Inteligência Artificial (IA) no controle e detecção de doenças em plantas representa um avanço significativo na agricultura contemporânea, podendo desempenhar um papel essencial na detecção precoce, diagnóstico preciso e gestão eficaz das enfermidades que afetam as plantações. Este avanço tecnológico oferece uma abordagem inovadora para enfrentar os desafios fitossanitários na indústria agrícola, independentemente do tipo de cultura. As doenças vegetais representam uma ameaça constante à produtividade agrícola global e à segurança alimentar. Com o emprego da IA, os agricultores e especialistas têm acesso a ferramentas avançadas para detectar e monitorar doenças em estágios iniciais e realizar tomadas de decisão precisas e em tempo hábil. É possível identificar na literatura que algoritmos de aprendizado de máquina (*Machine Learning*), redes neurais e sistemas especializados são muito utilizados para identificar padrões, sintomas e comportamentos anômalos, permitindo respostas mais ágeis e precisas aos problemas fitossanitários. Entretanto, o uso da Inteligência Artificial propriamente dita para tomada de decisões no manejo integrado de doenças ainda não é muito utilizado. O objetivo desta pesquisa foi identificar os ganhos do uso da tecnologia de Inteligência Artificial (IA) no manejo integrado de doenças em plantas através de uma revisão da literatura. Contudo, com o resultado da pesquisa foi possível constatar que o uso da IA ainda não é muito abrangente no manejo agrícola, por mais que a utilização de aspectos que compõem a IA como *Machine Learning* sejam amplamente utilizados e alcancem resultados muito positivos.

**Palavras-chave:** Inteligência Artificial (IA); Controle de doenças; Agricultura; Manejo de doenças; Aprendizado de máquina.

## INTRODUÇÃO

A agricultura assume, atualmente, o papel de uma das principais atividades responsáveis pela segurança alimentar global e tem estado neste posto desde o início da história da sociedade como conhecemos hoje. Por isto, mais do que nunca, a agricultura tem enfrentado desafios fitossanitários como doenças de plantas capazes de

reduzir ou até mesmo eliminar completamente a produtividade de plantações inteiras (Arora, 2019).

A identificação precisa e o controle eficaz destas doenças são cruciais para garantir sustentabilidade ao setor e à sociedade. Prevê-se que a população global, até 2050, pode alcançar a marca aproximada de 10 bilhões de pessoas, conforme a *Food and Agriculture of United Nations (FAO)* (Arora, 2019)

Com esse aumento populacional em mente, controlar a produção agrícola é de suma importância para que se possa atender essa demanda por alimento nos próximos anos (Arora, 2019).

Neste cenário, a Inteligência Artificial (IA) surge como uma solução inovadora e eficaz para auxiliar o manejo integrado destas doenças, oferecendo meios e tecnologias capazes de detectar, prever e monitorar doenças de plantas automatizadas e em tempo real.

Mediante algoritmos de aprendizagem de máquina (*Machine Learning*) e redes neurais, a IA possibilita a identificação precoce de doenças em plantas antes mesmo do surgimento de sintomas visíveis aparecerem, sendo isso um aspecto vital para uma intervenção rápida e efetiva. Em sua pesquisa bibliográfica, Jafar *et al.* (2024) demonstraram através do levantamento de resultados e pesquisas de trabalhos que utilizam a tecnologia, a efetividade da IA em melhorar a precisão na classificação de doenças e, com isso, possibilitar a redução do uso de defensivos agrícolas, contribuindo para práticas agrícolas mais sustentáveis.

Diante disso, este presente estudo propõe uma revisão bibliográfica. De acordo com Marconi e Lakatos (2003), a revisão bibliográfica se trata da pesquisa e análise de materiais ou fontes literárias que tratam do assunto alvo do trabalho, permitindo destacar as principais conclusões de outros autores e identificar contradições ou semelhanças. Esta pesquisa foi realizada visando identificar e analisar o uso de tecnologias de Inteligência Artificial (IA) no manejo de doenças em culturas agrícolas e evidenciar quais os resultados que vêm sendo obtidos com a implementação desta tecnologia.

## 2 MATERIAIS E MÉTODOS

Para realizar esta revisão foram realizadas buscas sistematizadas nas bases de dados eletrônicas SCIELO e Google Acadêmico, além de *sites* especializados no tema. As buscas não foram limitadas por idioma, apenas por data de publicação e foram priorizados artigos publicados entre 2020 e 2024, com algumas ressalvas para pontos específicos que não mudaram ao longo dos anos, contemplando literatura nacional e internacional de forma a manter os dados o mais atualizados possível.

As palavras-chave utilizadas incluíram "Inteligência Artificial", "Manejo de Doenças Agrícolas", "Detecção de doenças em plantas", "Manejo de doenças" e "Agricultura 4.0", combinadas com operadores booleanos AND e OR para refinar os resultados e garantir que apenas estudos que abordassem IA aplicada ao manejo de doenças fossem selecionados. Foram levantados com essa pesquisa 50 trabalhos e destes foram selecionados 30 entre artigos, dissertações e teses localizados em *sites*, livros e periódicos.

## 3 RESULTADOS E DISCUSSÃO

### 3.1 Inteligência Artificial e *Machine Learning*

A Inteligência Artificial (IA) é uma tecnologia que possibilita a realização de tarefas que normalmente exigiriam inteligência humana, como raciocínio, aprendizado, percepção e tomada de decisões (IBM, 2024). De acordo com Rouhiainen (2018), a IA refere-se à capacidade das máquinas de aprenderem com dados e tomarem decisões autônomas, simulando processos cognitivos humanos. Diferentemente das pessoas, as IA's são capazes de processar grandes volumes de informações de forma contínua e eficiente, gerando diagnósticos e previsões mais rápidos e precisos.

As aplicações da IA abrangem uma vasta gama de setores, incluindo automóveis autônomos que detectam e evitam obstáculos, assistentes robóticos que realizam diagnósticos médicos com alta precisão e sistemas de tradução automática que facilitam a comunicação entre diferentes idiomas (Ludermir, 2021). No setor agrícola, a IA tem um

potencial crescente para revolucionar como as doenças em culturas agrícolas são monitoradas e gerenciadas.

A Inteligência Artificial pode ser dividida em três categorias principais: IA Focada, IA Generalizada e IA Superinteligente. A IA Focada (ou IA Fraca) refere-se a sistemas projetados para resolver problemas específicos, como os sistemas de recomendação e os sistemas especialistas, programados para executar tarefas específicas com eficiência (Institute of Data, 2023).

A IA Generalizada (ou IA Forte), por outro lado, envolve algoritmos que podem realizar uma variedade de tarefas de forma autônoma, com habilidades semelhantes às humanas. Um exemplo é a visão computacional usada para identificar e analisar imagens de forma precisa. (Borana, 2016).

Um dos pilares fundamentais que compõe a tecnologia de Inteligência Artificial é o *Machine Learning* (ML), ou aprendizado de máquina, que permite que os sistemas melhorem seu desempenho com o tempo ao aprenderem com os dados (Russel, Norving, 2016). Em vez de serem programados explicitamente para cada tarefa, os sistemas de ML utilizam algoritmos que processam vasta quantidade de dados para detectar padrões, fazer previsões e tomar decisões. Isso é particularmente relevante para a agricultura, onde variáveis como clima, solo e doenças das plantas são altamente dinâmicas e imprevisíveis.

O ML é amplamente utilizado em aplicações como reconhecimento de padrões, automação de processos e tomada de decisões. Ele é categorizado em aprendizado supervisionado e aprendizado não supervisionado. No aprendizado supervisionado, os algoritmos são treinados com dados rotulados, ou seja, os exemplos de treinamento incluem as respostas corretas, o que permite que o sistema aprenda a classificar ou prever novos dados com base nesse treinamento. Exemplos de algoritmos supervisionados incluem: Redes Neurais, Regressão Linear, *Naive Bayes* e Máquinas de Vetores de Suporte (IBM, 2023).

Por outro lado, no aprendizado não supervisionado, os dados fornecidos ao algoritmo não são rotulados, e o sistema deve descobrir padrões e relações por conta própria. Isso é útil em tarefas como agrupamento de dados e redução de dimensionalidade, onde o objetivo é encontrar padrões ocultos sem intervenção humana. O aprendizado não supervisionado é essencial para a análise de grandes volumes de

dados agrícolas, permitindo a detecção precoce de padrões complexos que podem indicar a presença de doenças ou outras anomalias nas culturas (IBM, 2023).

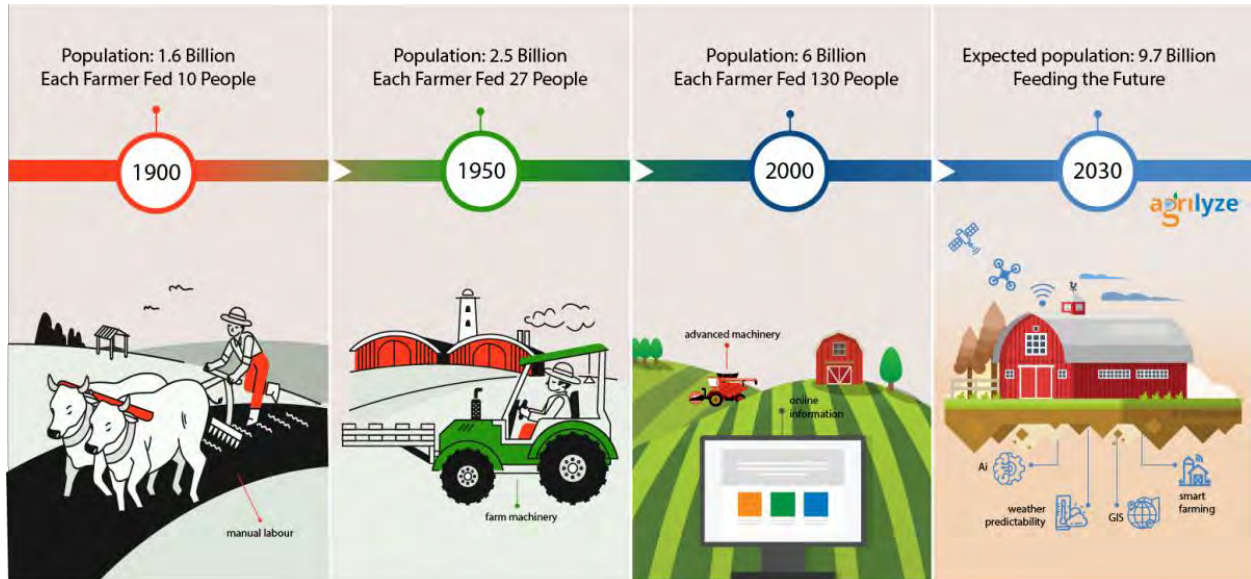
A integração de IA e ML no manejo de doenças agrícolas tem o potencial de transformar o setor, fornecendo ferramentas avançadas para monitoramento, diagnóstico e intervenção, resultando em maior produtividade e sustentabilidade. Essas tecnologias permitem que os agricultores adotem uma abordagem mais proativa e precisa no combate a doenças, reduzindo a dependência de insumos químicos e otimizando o uso de recursos.

### **3.2 Aplicações da Agricultura de Precisão no Manejo de Doenças**

A agricultura como a conhecemos hoje é resultado de milênios de evolução e aprimoramento das técnicas de cultivo de alimentos, associadas ao desenvolvimento social e econômico da humanidade. Esse processo foi acelerado pela necessidade de adaptação às mudanças climáticas e pelo instinto de sobrevivência, que levaram o ser humano a organizar-se em comunidades maiores e a produzir seus próprios alimentos em larga escala. Nesse novo contexto social, a agricultura tornou-se a base da sobrevivência, sustentando o desenvolvimento das sociedades humanas ao longo dos séculos (Anderson *et al.*, 2020).

Castanho e Teixeira (2017) definem agricultura como uma atividade voltada ao cultivo do solo, com o objetivo de produzir vegetais tanto para o consumo humano quanto para o suprimento da demanda na criação de animais. Nesse sentido, a agricultura envolve não apenas o ato de cultivar, mas também o trabalho e as técnicas utilizadas para a obtenção de produtos agrícolas. Assim, trata-se de uma prática que remonta às primeiras civilizações e que, ao longo do tempo, foi se adaptando às novas exigências econômicas e tecnológicas, adaptação essa que é exemplificada na figura abaixo, se tornando a Agricultura que temos hoje.

Figura 1 - Evolução da Agricultura Moderna



Fonte: Agrilyze (2024)

A introdução de tecnologias modernas, como o sensoriamento remoto e os Sistemas de Informações Geográficas (GIS), foi crucial para o surgimento da agricultura de precisão, um campo que combina ciência, tecnologia e práticas agrícolas para otimizar a produtividade e a qualidade das lavouras. Conforme apontado por Pierce e Nowak (1999), essa abordagem busca gerenciar e observar variáveis naturais do campo com precisão, reduzindo incertezas e permitindo o uso mais eficiente dos recursos disponíveis. O conceito, embora já tivesse suas raízes antes da Segunda Revolução Industrial, ganhou força nos anos 1980, quando o uso de satélites, maquinários autônomos e sistemas embarcados se tornou viável para o setor agrícola (Gebbers, Adamchuk, 2010).

A agricultura de precisão, com o suporte das tecnologias da informação, permite a padronização dos processos produtivos, garantindo uma melhor qualidade na produção agrícola. Inicialmente, esse método foi aplicado principalmente para a distribuição equilibrada de defensivos, mas com os avanços na tecnologia, abriu-se espaço para implementos autônomos, sistemas de rastreabilidade de produtos e ferramentas avançadas de gerenciamento agrícola, transformando a agricultura moderna em um campo altamente tecnológico e eficiente (Lamparelli, 2022). A figura

abaixo exemplifica os processos dentro da agricultura de precisão e quais áreas tecnológicas a complementa atualmente.

Figura 2 - Aspectos Agricultura de Precisão



Fonte: CHBAGRO (2020)

No contexto do manejo de pragas e doenças, o Manejo Integrado de Doenças (MID) se destaca como uma abordagem que combina diferentes métodos com o objetivo de manter os organismos nocivos abaixo do Limiar de Dano Econômico (LDE). Esses métodos incluem o controle biológico, químico, genético, cultural e físico (Rohrig, 2021). O manejo biológico, por exemplo, envolve a introdução de organismos que competem com as pragas ou doenças, podendo ocorrer naturalmente ou através de intervenção

humana. O controle químico consiste na aplicação de defensivos agrícolas nas culturas para combater e eliminar as pragas e conter doenças. Embora eficaz, esta estratégia requer cautela devido aos riscos ambientais e à saúde humana decorrentes de sua aplicação inadequada.

O manejo genético, por sua vez, consiste na utilização de culturas geneticamente resistentes a doenças e pragas específicas, sendo uma alternativa eficiente e menos prejudicial ao meio ambiente. Para implementá-lo, é necessária uma pesquisa detalhada das pragas mais comuns na região, permitindo a seleção de cultivares mais resistentes. Em alguns casos, essa pode ser a única opção viável (Rohrig, 2021). Já o manejo cultural envolve práticas como a rotação de culturas, o uso de sementes saudáveis e o tratamento do solo, com o objetivo de criar condições desfavoráveis ao desenvolvimento de patógenos.

Por fim, o manejo físico refere-se ao controle das variáveis ambientais, como temperatura e radiação, para prevenir o surgimento de doenças nas plantas. No entanto, essa técnica é menos utilizada devido ao alto custo e à possibilidade de redução na produtividade das culturas (Rohrig, 2021).

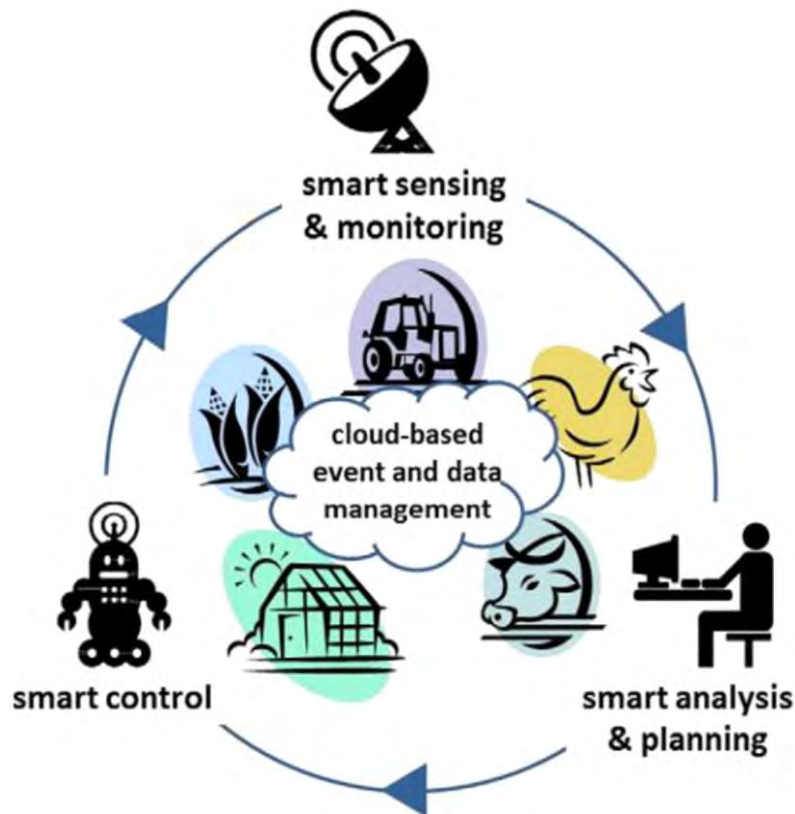
Em todos esses métodos, é necessário monitorar uma série de fatores, como o ambiente, o estado das plantas e o estágio de desenvolvimento da doença. O número elevado de variáveis torna o processo complexo e aumenta o risco de erros, o que pode resultar em perdas significativas para a produção. A integração dessas práticas com tecnologias de *Machine Learning* (ML) e Inteligência Artificial (IA) pode otimizar o monitoramento e a tomada de decisões, minimizando riscos e melhorando a eficiência no campo.

### **3.3. Inteligência Artificial no Manejo Integrado de Doenças em Plantas**

A agricultura inteligente, também conhecida como *Smart Farming*, representa a inserção de tecnologias inovadoras e, muitas vezes, disruptivas no campo agrícola, incluindo o uso de Inteligência Artificial (IA) para otimizar tanto a produtividade quanto a eficiência das operações. Como destacado por Mohamed *et al.* (2021), essa abordagem é fundamental para o controle de pragas e doenças, que têm impacto direto na saúde das plantas e, conseqüentemente, na produção agrícola como um todo. A agricultura

inteligente utiliza uma ampla gama de ferramentas durante o processo de cultivo e monitoramento, garantindo uma gestão mais eficiente das plantações (Hashem, Joudeh, Zamil, 2024). Entre os exemplos mais comuns dessas tecnologias estão: o sensoriamento remoto, a Internet das Coisas (IoT), a análise de dados em larga escala, os Sistemas de Informação Geográfica (GIS) e a robótica. Funcionando em conjunto uma com a outra, como apresenta a imagem abaixo.

Figura –3 Smart farming cycle



Fonte: Mohamed *et al.* (2021)

Essas inovações visam melhorar a produtividade agrícola, otimizar o uso dos recursos naturais e combater pragas de maneira mais sustentável e eficaz (Gupta *et al.*, 2020).

O uso de aprendizagem de máquina no manejo de doenças em plantas representa um papel muito importante no *Smart Farming*. Com ela é possível identificar com precisão e antecedência vários tipos de doenças. Com isso, é possível otimizar os processos de tratamento com eficácia financeira e ecológica. No campo, o aprendizado

de máquina tem assumido um papel muito importante, quase indispensável, para a agricultura contemporânea. Estudos realizados por Toscano-Miranda *et al.* (2022) na cultura do algodão demonstraram resultados promissores na identificação da praga "mosca-branca" e da doença "Podridão Radicular". Utilizando visão computacional e algoritmos de segmentação, como *K-means*, foi possível identificar essas pragas e doenças com alta precisão. Esses resultados atingidos com o aprendizado de máquina indicam que a aplicação de IA no Manejo Integrado de Pragas (MIP) pode reduzir significativamente o impacto ambiental associado ao uso de defensivos químicos, minimizando os riscos para o meio ambiente, além de proteger a vida humana e animal.

Culturas com grande expressão econômica mundial têm se beneficiado do uso de tecnologias que compõem a IA para o manejo de doenças. No campo da soja, Costa (2023) aplicou redes neurais convolucionais, especificamente a arquitetura MobileNetV2, para analisar e classificar imagens de folhas contaminadas por diversas doenças e fungos. O estudo atingiu uma acurácia de 92%, utilizando uma base de dados de 815 imagens divididas em conjuntos de treinamento, validação e teste. Por mais que apresente limitações geradas pelo baixo volume de dados disponíveis para análise, este trabalho já demonstra claramente a viabilidade da aplicação de IA para o diagnóstico precoce de doenças e fungos e tomada de decisão assertiva, o que pode aprimorar significativamente a gestão fitossanitária no campo.

Em outro estudo, Silva (2023) alcançou uma acurácia de 97,95% utilizando a arquitetura de rede neural convolucional ResNet-50 para identificar doenças foliares em videiras. Com base no *Grape Disease Dataset*, que contém 9.027 imagens, os resultados indicam o enorme potencial das redes neurais para identificar doenças de forma eficiente e precisa. Em estágios iniciais de pesquisa, a tecnologia já mostra grande versatilidade na aplicação, alcançando resultados expressivos com relativo baixo volume de dados.

Por sua vez, Oliveira (2022) propôs um modelo de rede neural convolucional para a classificação de doenças foliares em cafeeiros, atingindo uma precisão de 90% na identificação de doenças como *mancha de phoma*, *cercospora* e ferrugem.

O modelo também apresentou um f1-score de 93,3% na classificação entre plantas saudáveis e doentes. A pesquisa destacou o uso de técnicas de aumento de dados e a consideração dos três canais de cor das imagens como fatores que contribuíram para os bons resultados. No entanto, o estudo também apontou desafios

na distinção de amostras com características visuais muito semelhantes, como no caso da ferrugem e da mancha de *phoma*, revelando que, apesar do grande potencial das redes neurais, ainda há obstáculos a serem superados para garantir a identificação precisa de todas as doenças. Estes obstáculos são possíveis de serem superados com um aumento da base de dados utilizada no processo de aprendizagem e um aumento na variedade das imagens, apresentando os vários sintomas em suas fases distintas.

O uso de ML se estende para a análise de sintomas causados por pragas (insetos ou ervas daninhas que competem com a cultura cultivada), que por sua vez geram doenças em plantas. Crispi (2022) destaca em seu trabalho o desempenho de diferentes arquiteturas neurais convolucionais ou modelos de aprendizagem de máquina em identificar através de imagens os sintomas causados pela mosca-minadora em folhas de tomates. Através das comparações dos resultados, ele concluiu que a arquitetura FPN, junto com a arquitetura DenseNet121, obteve o melhor desempenho na identificação de alvos em imagens com um fundo complexo. Porém, um desafio apresentado em sua pesquisa, que aparenta ser comum em quase todos os estudos relacionados a aplicação de ML para a identificação de sinais de doenças em plantas, é a falta de robustez e variedade no conjunto de dados utilizados para o aprendizado. Por mais que apresente este desafio, a pesquisa apresenta resultados relevantes para o avanço do uso de IA na agricultura, demonstrando o potencial tecnológico para a detecção precoce de doenças e o aprimoramento do manejo integrado de pragas.

Áreas de grande impacto e importância econômica nacional, como o setor florestal brasileiro, fornecedor de matéria-prima para áreas de reflorestamento e suprimento industrial, como mudas de árvores e carvão, respectivamente, são contempladas pelo ganho evidente que o uso de ML para identificação e manejo de doenças pode trazer (Favan, 2015).

Em sua pesquisa, Favan (2015) apresenta a viabilidade de Redes Neurais Artificiais (RNA) para a detecção de doenças em mudas de eucalipto. Com a obtenção média de acurácia em torno de 95,34% na classificação de imagens utilizadas na pesquisa, usando uma topologia com 256 neurônios artificiais na camada intermediária, a RNA desenvolvida apresenta o menor erro quadrático médio (0,45115), indicando o melhor ajuste do modelo aos dados utilizados, sem comprometer a precisão da classificação.

Caldeira (2020) apresenta em seu trabalho o desenvolvimento de um *software* para a identificação de folhas saudáveis e doentes no algodoeiro utilizando algoritmos de aprendizagem de máquina. Este *software* alcançou uma precisão de 84,3%, permitindo o suporte à tomada de decisão no manejo integrado de doenças em plantas. Entre os algoritmos de aprendizagem de máquina utilizados e testados no trabalho, o ConvNet se destacou, atingindo uma taxa de precisão média de 88,30% na classificação global, com uma variação entre 79% e 98% para classes individuais. Com estes resultados, o algoritmo ConvNet demonstrou uma robustez, mesmo as imagens estando em condições diferentes de iluminação, condições essas que podem prejudicar a qualidade da identificação e resultados gerais.

Pereira (2022) apresenta em seu trabalho a aplicação do aprendizado de máquina, utilizando os algoritmos SVM (*Support Vector Machine*), para identificar as doenças nas folhas do arroz. Depois de realizada a otimização dos parâmetros por meio da técnica *Grid Search*, sendo os melhores valores  $C = 1000$ ,  $\text{Gamma} = 100$  e kernel RBF, o modelo foi capaz de alcançar uma precisão de 81,81%. A robustez da avaliação foi confirmada através da avaliação cruzada, com uma acurácia média de 80,67% e um desvio padrão de 2,46%. Com isso demonstrando que, embora o desempenho tenha ficado abaixo de 90% o método de aprendizagem apresentou resultados satisfatórios para o auxílio na tomada de decisão para o manejo de doenças na cultura do arroz.

Nogueira (2020) apresenta em seu trabalho a utilização de um algoritmo de aprendizagem de máquina chamado *Random Forest*, usado para detectar, através de imagens de satélite, sintomas de infecções causadas por nematoides a lavoura de soja. A alta acurácia dos modelos utilizados, com índices Kappa superiores a 0,8 em algumas épocas, demonstra a viabilidade da utilização da ferramenta para realizar o monitoramento e auxiliar na tomada de decisão relacionada ao manejo de doenças e pragas. O trabalho apresenta os mesmos desafios que os trabalhos anteriores apresentaram: a dificuldade de coleta e falta de dados para aumentar a robustez do banco de dados.

A literatura internacional também tem apresentado resultados positivos com o uso de técnicas de aprendizado de IA. Toscano-Miranda *et al.* (2022) apresentam que técnicas de Inteligência Artificial, como máquinas de vetores de suporte (SVM), redes neurais convolucionais (CNN) e algoritmos de segmentação de imagem, têm sido

amplamente empregadas para o manejo de pragas e doenças em plantações de algodão. Este trabalho também destaca que as tendências tecnológicas no manejo de doenças no cultivo de algodão estão cada vez mais direcionadas para o uso de técnicas avançadas de Inteligência Artificial, como redes neurais convolucionais (CNN) e algoritmos de aprendizado profundo.

Essas abordagens oferecem maior precisão na detecção e diagnóstico, enquanto o uso de sensores, como câmeras e dispositivos de monitoramento ambiental, possibilita a coleta de dados em tempo real. No entanto, os autores ressaltam a necessidade de modelos preditivos e prescritivos para antecipar surtos e definir estratégias de controle, apontando para o futuro da agricultura de precisão assistida por IA (Toscano-Miranda *et al.* 2022).

Raju *et al.* (2022) apresentam em seu trabalho o desenvolvimento de um sistema completo de Irrigação Hidropônica Inteligente utilizando tecnologias de IoT (*Internet of Things*) e ML para monitoramento e manejo de doenças em plantas hidropônicas. Esta abordagem utilizou uma Rede Neural Convolucional de Aprendizado Profundo para classificar doenças em diversas culturas, atingindo uma acurácia de 99,29% e um F-measure de 99.23%. Com estes resultados a aplicação daria sugestões de quais ações realizar e, baseado nestas sugestões e resultados, o agricultor toma a decisão. Estes resultados entre a integração de IoT e ML mostram o valor agregado ao manejo de doenças que a tecnologia oferece.

Em seu trabalho de graduação, Silveira, Santos e Barbosa (2022) apresentam os resultados de sua tentativa de utilizar técnicas de ML para detectar pragas e doenças na folha da soja a partir do uso de imagens. Embora o objetivo apresente relevância e as ferramentas utilizadas sejam adequadas, o estudo apresentou algumas limitações. A principal limitação apresentada se trata da mesma que todos os trabalhos na área apresentam, a falta de dados suficientes para o treinamento do modelo de forma robusta, resultando em uma acurácia muito inferior à esperada, com base em resultados já encontrados na literatura atual.

Com sua extensa revisão de 176 estudos selecionados a partir de um total de 1349 artigos, Shafik *et al.* (2023) concluíram que diversas técnicas de aprendizado de máquina e aprendizado profundo, foram amplamente aplicadas na detecção de doenças de plantas. Classificadores como Máquinas de Vetores de Suporte (SVM) e Regressão

Logística (*Logistic Regression*) mostraram melhorias significativas em termos de precisão, especialmente em abordagens de imagens hiper espectrais, com modelos baseados em Redes Neurais Convolucionais (CNN).

Embora existam resultados positivos do uso de *Machine Learning* (ML), a aplicação de Inteligência Artificial (IA) no manejo de doenças em plantas ainda é limitada. Segundo Rani et al. (2023), a adoção dessa tecnologia na detecção de doenças enfrenta desafios significativos, como a falta de dados de qualidade e a integração de tecnologias de captura de imagens no campo. Um exemplo disso é a complexidade das imagens de plantas e a necessidade de processamento em tempo real.

A IA apresenta potencial, mas ainda são necessários avanços para que a tecnologia seja amplamente adotada pelos agricultores de forma geral. Existe hoje a necessidade de se continuar investindo em pesquisa e desenvolvimento para superar estas limitações atuais no setor, para poder tornar a IA uma ferramenta mais acessível e eficaz para o manejo de doenças nas culturas. (Rani et al. 2023)

#### **4 CONSIDERAÇÕES FINAIS**

Por fim, ao observar os dados coletados nesta pesquisa foi possível concluir que o aprendizado de máquina (*Machine Learning*) tem gerado resultados significativos no manejo de doenças em plantas como na identificação e categorização, de forma precisa, de doenças em plantas. Os estudos apresentados demonstram resultados que comprovam a eficiência de algoritmos como SVM, Redes Neurais Convolucionais, entre outros, em possibilitar a mitigação de danos às lavouras através da identificação precisa e precoce de doenças.

Durante a pesquisa, porém, foi identificado uma evidente lacuna entre o uso destes algoritmos e a aplicação mais ampla da Inteligência Artificial (IA) propriamente dita. Enquanto o aprendizado de máquina é amplamente usado para identificar e classificar doenças, a IA, que engloba aspectos mais complexos de tomada de decisão e automação de processos, ainda é subutilizada no contexto de manejo integrado de doenças em plantas. Embora a literatura atual apresente muitos resultados positivos em relação ao aprendizado de máquina, o emprego de modelos de IA para tomada de

decisões mais abrangentes no manejo de plantas permanece pouco explorado, até mesmo na literatura estrangeira.

Portanto, é crucial que futuros trabalhos e pesquisas visem aplicar o uso da IA para além da identificação e classificação de doenças por meio do aprendizado de máquina. É necessário integrar a IA nas estratégias de manejo, permitindo aos sistemas inteligentes tomarem decisões autônomas sobre o controle de pragas e o uso eficiente de insumos agrícolas. Isso maximizaria os benefícios já trazidos pelo aprendizado de máquina, mas também potencializaria o impacto desta tecnologia emergente no agronegócio.

## **REFERÊNCIAS**

AGRILYZE. **Solutions**. Past, present, future: The Evolution of Agriculture. Disponível em: <https://agrilyze.ca/farm-solutions-farmers-data-for-precision-farming/>. Acesso em: 24 out. 2024.

ANDERSON, C. G.; FERREIRA, P. C.; RESENDE, L. L. de; PUTTI, F. F.; GÓES, B. C. In: SILVA, A. L. C. da; GÓES, B. C; PUTTI, F. F. **A Modernização da Agricultura e o Caso Brasileiro**. 1. ed. Tupã, SP: Anap, 2020. cap. 2, p. 53-73.

ARORA, N. K. Impact of climate change on agriculture production and its sustainable solutions. **Environmental Sustainabil.** [S.l.], v. 2, n. 2, p. 95-96, jun. 2019.

BORANA, J. **Applications of Artificial Intelligence & Associated Technologies**. Bacharelado em Tecnologia - Jodhpur National University, Jodhpur, 2016

CALDEIRA, R. F. **Detecção de doenças na cultura do algodoeiro através de processamento digital de imagens**. Orientadora: Bárbara Janet Teruel Mederos. 2020. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola, Campinas, 2020.

CASTANHO, R. B.; TEIXEIRA, M. E. S. A evolução da agricultura no mundo: da gênese até os dias atuais. **Brazilian Geographical Journal**, Ituiutaba, MG, v. 8, n. 1, p. 136-146, 2017.

CHBAGRO. **Blog**. Plantação de milho e o papel da agricultura de precisão, [2020]. Disponível em: <https://chbagro.com.br/blog/plantacao-de-milho-e-o-papel-da-agricultura-de-precisao>. Acesso em: 24 out. 2024.

COSTA, R. P. da. **Identificação de Doenças em Folhas de Soja Utilizando Redes Neurais Convolucionais**. Orientador: Mauri Ferrandin. 2023. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Controle e Automação) - Universidade Federal de Santa Catarina, Centro Tecnológico de Ciências Exatas e Educação, Blumenau, 2023.

CRISPI, G. M. **Uso de Redes Neurais Profundas na Avaliação do Ataque de Mosca Minadora ao Tomateiro**. 2022. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2022.

FAVAN, J. R. **Utilização de Redes Neurais Artificiais Aplicadas na Discriminação de Padrões de Doenças Florestais**. Dissertação (Mestrado em Ciência Florestal) - Faculdade de Ciências Agrônômicas da UNESP, Botucatu, 2015.

GEBBERS, R.; ADAMCHUK, V. I. Precision Agriculture and Food Security. **Science**, v. 327, n. 5967, p. 828-831, fev. 2010.

GUPTA, Maanak; ABDELSALAN, Mahmoud; KHORSANDROO, Sajad; MITTAL, Sudip. Security and Privacy in Smart Farming: Challenges and Opportunities. **IEEE Access**, [S.l.], v. 8, p. 34564-34584, fev. 2020.

HASHEM, T. N.; JOUDEH, J. M. M.; ZAMIL, A. M. Smart Farming (Ai-Generated) as an Approach to Better Control Pest and Disease Detection in Agriculture: POV Agricultural Institutions. **Migration Letters**, London, UK, v. 21, n. S1, p. 529-547, 2024.

IBM. **Think**. O que é Inteligência Artificial IA? Disponível em: <https://www.ibm.com/br-pt/topics/artificial-intelligence>. Acesso em: 07 out. 2023.

IBM. **Início**. O que é Aprendizado não supervisionado? Disponível em: <https://www.ibm.com/br-pt/topics/unsupervised-learning>. Acesso em: 10 out. 2023.

IBM. **Think**. O que é aprendizado supervisionado? Disponível em: <https://www.ibm.com/br-pt/topics/supervised-learning>. Acesso em: 10 out. 2023.

Institute of Data. **Blog**. Exploring the Differences Between Narrow AI, General AI, and Superintelligent AI. Disponível em: <https://www.institutedata.com/blog/exploring-the-differences-between-narrow-ai-general-ai-and-superintelligent-ai/>. Acesso em: 12 dez. 2024.

JAFAR, Abbas; BIBI, Nabila; NAQVI, Rizwan Ali; SADEGHI-NIARAKI, Abolghasem; JEONG, Daesik. Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. **Frontiers in Plant Science**, v. 15, p. 1-20, mar. 2024.

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos de Metodologia Científica**. 5. ed. São Paulo: Atlas S.A., 2003.

LAMPARELLI, R. A. C. Agricultura de Precisão. In: **Embrapa**. Brasília, 22 fev. 2022. Disponível em: <https://www.embrapa.br/en/agencia-de-informacao-tecnologica/cultivos/cana/producao/avanco-tecnologico/agricultura-de-precisao>. Acesso em: 17 out. 2024.

LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, [S.l.], v. 35, p. 85-94, 2021.

MOHAMED, Elsayed Said; BELAL, Abd El Aziz; ABD-ELMABOD, Sameh Kotb; EL-SHIRBENY, Mohammed A; GAD, Abd Alla; ZAHRAN, Mohamed Bayoumy. Smart farming for improving agricultural management. **The Egyptian Journal of Remote Sensing and Space Science**, [S.l.], v. 24, n. 3, p. 971-981, dez. 2021.

NOGUEIRA, L. C. A. **Machine Learning para Detecção de *Pratylenchus brachyurus* na Cultura da Soja Utilizando Imagens MSI/SENTINEL-2**. 2020. Dissertação (Mestrado em Ciências Agrárias - Agronomia) - Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, 2020.

OLIVEIRA, C. T. de. **Monitoramento da Maturação dos Frutos e de Doenças do Cafeeiro Utilizando Modelos de Deep Learning**. 2022. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2022.

PEREIRA, G. M. **Classificação de Doenças na Folha do Arroz Através de Processamento de Imagens e Aprendizado de Máquina**. Orientador: Joceli Mayer. 2022. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) - Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2022.

PIERCE, F. J.; NOWAK, P. Aspects of Precision Agriculture. *In*: SPARKS, D. L. **Advances in Agronomy**. 1. ed. Delaware: Academic Press, 1999. V. 67, p. 1-85.

RAJU, S. V. S. R.; DAPPURI, B.; VARMA, P. R. K.; YACHAMANENI, M.; VERGHESE, D. M. G.; MISHRA, M. K. Design and Implementation of Smart Hydroponics Farming Using IoT-Based AI Controller with Mobile Application System. **Journal Of Nanomaterials**, London, UK, v. 2022, n. 1, p. 1-12, jan. 2022.

RANI, Ruchi; SAHOO, Jayakrushna; BELLAMKONDA, Sivaiah; KUMAR, Sumit; PIPPAL, Sanjeev Kumar. Role of Artificial Intelligence in Agriculture: An Analysis and Advancements With Focus on Plant Diseases. **IEEE Access**, [S.l.], v. 11, p. 137999-138019, 2023.

ROHRIG, B. Como o Manejo Integrado de Doenças pode reduzir custos e aplicações no seu cultivo. *In*: **Aegro**. Porto Alegre, 13 set. 2021. Disponível em: <https://blog.aegro.com.br/manejo-integrado-de-doencas>. Acesso em: 20 out. 2023.

ROUHIAINEN, Lasse. **Inteligência Artificial: 101 coisas que precisa saber hoje sobre nosso futuro**. 1. ed. Barcelona: Alienta Editorial, 2018.

RUSSEL, Stuart Jonathan; NORVING, Peter. **Artificial intelligence: A Modern Approach**. 2. ed. New Jersey: Pearson, 2016.

SILVA, A. M. M. da. **Redes Neurais Convolucionais na Agricultura: Detecção de Doenças Fúngicas em Plantas de Uva**. Orientador: Matheus da Silva Menezes. 2023. Trabalho de Conclusão de Curso (Bacharelado em Ciência e Tecnologia) - Universidade Federal Rural do Semiárido, Mossoró, 2023.

SILVEIRA, B.; SANTOS, D. P. dos; BARBOSA, K. N. **Utilização de IA para Controle de Pragas na Agricultura**. Orientador: William Pereira dos Santos Júnior. 2022. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de *Software*) - Universidade Evangélica de Goiás, Anápolis, 2022.

SHAFIK, Wasswa; TUFAIL, Ali; NAMOUN, Abdallah; SILVA, Liyanage Chandratilak de; APONG, Rosyzie Anna Awg Haji Mohd. A Systematic Literature Review on Plant Disease Detection: motivations, classification techniques, datasets, challenges, and future trends. **IEEE Access**, [S.l.], v. 11, p. 59174-59203, 2023.

TOSCANO-MIRANDA, Raul; TORO, Mauricio; AGUILAR, José.; CARO, Manuel; MARULANDA, Alejandro; TREBILCOK, Anibal. Artificial-intelligence and sensing techniques for the management of insect pests and diseases in cotton: a systematic

literature review. **The Journal of Agricultural Science**, [S.l.], v. 160, n. 1-2, p. 16-31, fev. 2022.