

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI  
INSTITUTO DE CIÊNCIAS AGRÁRIAS - ICA  
CURSO DE AGRONOMIA**

**DETECÇÃO DE PRAGAS E DOENÇAS NO ALGODOEIRO POR ANÁLISE DE  
IMAGENS**

**Unai**

**2023**

**Maria Luíza Alves Teixeira dos Santos**

**DETECÇÃO DE PRAGAS E DOENÇAS NO ALGODOEIRO POR ANÁLISE DE  
IMAGENS**

Monografia apresentada ao Instituto de Ciências Agrárias da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito para obtenção do título de Engenheira Agrônoma.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Renata Oliveira Batista  
Coorientador: Prof. Dr. Wesley Esdras Santiago

**Unai**  
**2023**

**Maria Luíza Alves Teixeira dos Santos**

**DETECÇÃO DE PRAGAS E DOENÇAS NO ALGODOEIRO POR ANÁLISE DE  
IMAGENS**

Monografia apresentada ao Instituto de Ciências Agrárias da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito para obtenção do título de Engenheira Agrônoma.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Renata Oliveira Batista

Data de aprovação 21/07/2023.

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Renata Oliveira Batista  
Instituto de Ciências Agrárias - UFVJM

---

Prof. Dr. Alceu Linares Pádua Junior  
Instituto de Ciências Agrárias - UFVJM

---

Prof. Dr. Rafael Faria Caldeira  
Instituto de Ciências Agrárias - UFVJM

**Unai**

## **DEDICATÓRIA**

A minha mãe, Irlene Alves Teixeira, que nunca mediu esforços para que eu pudesse realizar o meu sonho e sempre me incentivou nos momentos difíceis.

## **AGRADECIMENTOS**

Quero agradecer a toda minha família, em especial aos meus pais Irlene Alves Teixeira e Vilson Pereira da Silva, meus primos Flávio Egberto e Eliane Alves de Oliveira que sempre estiveram presentes nos meus estudos, que me apoiaram em todos os momentos que precisei.

Um agradecimento importante ao Ivan Pereira e ao grupo que trabalha com ele, a todos os funcionários pela recepção e pela disposição em toda a jornada na fazenda Futura.

A todos os meus professores do curso de Agronomia, da Universidade Federal dos Vales do Jequitinhonha e Mucuri pela excelência da qualidade técnica de cada um, pelo comprometimento em formar excelentes profissionais e coordenação do curso, por sempre estarem disponíveis para os alunos.

Por fim gostaria de agradecer aos meus orientadores, a professora e orientadora Renata Oliveira Batista, primeiramente ter sido uma professora excepcional durante a graduação e pelo privilégio de ser orientada por você. Sou grata aos professores Wesley Esdras Santiago e Rafael Faria Caldeira, por todo auxílio durante a execução do projeto e pela paciência em me ensinar.

## RESUMO

O algodão é uma cultura de grande relevância mundial devido a sua fibra diferenciada que serve como matéria-prima para indústrias têxteis. Além disso, seus subprodutos como o óleo e a semente atendem cadeias produtivas da indústria farmacêutica, de cosméticos e até mesmo alimentação animal. No Brasil, o crescimento da cotonicultura ocorreu em virtude do avanço para o bioma cerrado que possui clima favorável para a cultura, mas também para pragas e doenças limitando a produtividade e aumentando a demanda de defensivos agrícolas. Assim, visando estratégias que otimizem o manejo fitossanitário da cultura, ferramentas alternativas têm sido adotadas na detecção de pragas e doenças em plantas sintomáticas na cultura. Dentre elas, destaca-se a agricultura de precisão que auxilia na detecção de pragas e doenças para o uso racional de produtos fitossanitários. O objetivo deste trabalho foi analisar e processar imagens de plantas sintomáticas visando a detecção de pragas e doenças do algodoeiro. Para isto, foi formado um banco de imagens do dossel de lavouras de algodão com aproximadamente 1500 fotos. Cada imagem foi manualmente dividida em diferentes áreas de interesse com folhas saudáveis, folhas lesionadas e fundo da imagem. Posteriormente por meio de aprendizagem de máquinas, essas imagens foram classificadas pelo algoritmo de Redes Neurais Convolucionais (CNN). O desempenho da classificação foi verificado pelo coeficiente de Kappa e parâmetros de exatidão global, acurácia, sensibilidade, precisão, especificidade e F-score. Foi possível obter resultados notáveis com o algoritmo utilizado. O uso de redes neurais possibilitou alcançar altas taxas de precisão sem depender de uma grande quantidade de imagens, sendo, portanto, uma eficiente ferramenta para agricultura de precisão, bem como eficiente estratégia para uso racional dos produtos fitossanitários. Assim, conclui-se que o uso de softwares e algoritmos são eficientes no processamento de imagens de modo a auxiliar a detecção de lesões em lavouras de algodoeiro.

**Palavras-chave:** 1. *Gossypium hirsutum* L.; 2. Resnet 50; 3. Lesão; 4. Redes Neurais; 5. Algoritmo.

## ABSTRACT

Cotton is a crop with worldwide relevance due its topping fiber that is used for textile industry. In addition, its products, such as oil and seeds, are useful for pharmaceutical, cosmetics and even animal feed industries. In Brazil, the cotton crop occurred due to the advance towards the cerrado biome, which has a favorable climate for the crop, but also for pests and diseases, limiting yield and increasing the demand for agricultural pesticides. Thus, aiming strategies that optimize the phytosanitary management of the crop, alternative tools have been adopted in the detection of pests and symptomatic plants in the crop. Among them, precision agriculture stands out, which helps detect pests and diseases for the rational use of phytosanitary products. The objective of this work was to analyze and process images of symptomatic plants to detect pests and diseases in cotton. For this, lots of images from canopy of cotton crops was formed with approximately 1500 photos. Each image was manually divided into different areas of interest with healthy leaves, injured leaves and image background. Later, through machine learning, these images were classified by the algorithm of Convolutional Neural Networks (CNN). The classification performance was verified by the Kappa coefficient and parameters of global accuracy, accuracy, sensitivity, precision, specificity, and F-score, obtaining remarkable results. Thus, it is concluded that the use of software and algorithms are efficient in image processing to help detect lesions in cotton crops.

**Keywords:** 1. *Gossypium hirsutum* L.; 2. Resnet 50; 3. Lesion; 4. Neural Networks; 5. Algorith

## Sumário

1.	INTRODUÇÃO .....	11
2.	OBJETIVOS .....	14
3.	REVISÃO DE LITERATURA .....	15
3.1	A cultura do algodoeiro.....	15
3.1.1	<i>Histórico</i> .....	15
3.1.2	<i>Importância da cultura</i> .....	15
3.1.1.3	Cultivo de algodão .....	16
3.2	Agricultura de Precisão .....	17
3.2.1	<i>Veículo aéreo não tripulado (VANT)</i> .....	19
3.2.2	<i>Processamento digital de imagens</i> .....	19
3.3.	As redes neurais artificiais e convolucionais .....	21
3.3.1	<i>Perceptron- Rede neural de camada única</i> .....	21
3.3.2	<i>Redes Neurais Convolucionais (CNNs)</i> .....	24
3.3.2.1.	<i>Alguns componentes de uma CNN</i> .....	24
3.3.2.2	<i>Camada Convolucional</i> .....	24
3.3.2.3	<i>Função de ativação</i> .....	25
3.3.2.4.	<i>Camada de Pooling</i> .....	25
3.3.2.5.	<i>Camada totalmente conectada (fully-connected)</i> .....	26
3.4	A rede neural convolucional ResNet50.....	27
3.5	Alguns trabalhos atuais em inteligência artificial .....	28
4.	MATERIAIS E MÉTODOS .....	30
4.1	Obtenção de imagens.....	30
4.2	Pré-processamento das imagens e classificação das pragas e doenças .....	31
4.3	Aprendizado e classificação pelo algoritmo.....	33
4.4	Métricas de avaliação.....	34
5.	RESULTADOS E DISCUSSÃO .....	37
6.	CONSIDERAÇÕES FINAIS .....	41
7.	SUGESTÕES DE TRABALHOS FUTUROS.....	41
	REFERÊNCIAS.....	42



## 1. INTRODUÇÃO

O algodão é uma das fibras mais produzidas e comercializadas do mundo e é utilizada pelo homem há séculos. Devido às diversas cadeias produtivas que integra garante emprego a milhões de pessoas do campo a indústria. Nos últimos anos, o Brasil tem se mantido entre os cinco maiores produtores mundiais de algodão ao lado de países como China, Índia, Estados Unidos e Paquistão e entre os maiores exportadores mundiais. Atualmente, ocupa o primeiro lugar em produtividade da pluma em lavouras de sequeiro (ABRAPA, 2022).

Os maiores produtores de algodão do Brasil são os estados do Mato Grosso, Bahia, Goiás, Minas Gerais, Maranhão e Mato Grosso do Sul (ABRAPA, 2022). Mantendo praticamente a mesma área plantada na safra 2021/2022. O Brasil chegou a 3,0 milhões de toneladas de pluma na safra de 2022/2023. O que demonstra um aumento de produtividade em relação à safra anterior (CONAB, 2023).

Minas Gerais é um dos principais produtores da cultura no país, com 1,8% de participação no volume nacional e 29,4 mil hectares de cotonicultura. Dentro do Estado, a região Noroeste e Triângulo Mineiro foram responsáveis pela maior produção de algodão em 2021. Os municípios de Coromandel, Unaí, São Romão, Presidente Olegário e Brasilândia de Minas detém cerca de 54,1% de toda a produção do estado (SEAPA, 2022).

A maior produção de algodão em Minas Gerais e em todo Brasil está concentrada no bioma cerrado, visto que este bioma possui clima e topografia favoráveis ao uso de máquinas agrícolas (COSTA *et al.*, 2017). Berger, Lima e Oliveira (2019) ressaltam que investimento em pesquisa e tecnologia permitiu a criação de variedades adaptadas a essas regiões, tendo como resultado a alta produção (BERGER, LIMA e OLIVEIRA, 2019). Entretanto, o cerrado possui condições ambientais que favorecem o aumento nos níveis de pragas e doenças resultando em perdas econômicas expressivas (EMBRAPA, 2017).

A cultura do algodão é uma das mais desafiadoras do ponto de vista do controle de pragas e doenças que causam danos durante todo o ciclo da cultura inclusive pós-colheita. O algodão é hospedeiro de um amplo espectro de pragas e doenças que podem acometer raízes, caule, folhas, capulhos, botões florais e flores reduzindo a longevidade e a rentabilidade da cultura. Além das injúrias, alguns insetos sugadores podem provocar o aparecimento de doenças na cultura, por serem vetores de patógenos. Portanto, faz se necessário realizar o controle fitossanitário para não reduzir drasticamente a produção e qualidade de pluma (IKEDA, 2019).

Dentre as diversas doenças que acometem a cultura do algodoeiro, as doenças foliares são predominantes (PUIA *et al.*, 2021). Entre elas, a mancha de ramulária é conhecida como uma das principais doenças que acometem a cultura no cerrado brasileiro devido às condições ambientais que contribuem para a infecção, disseminação e sobrevivência do fungo *Ramularia gossypii*. Os sintomas da doença que são lesões angulares que podem acontecer em todas as fases da cultura e são vistas nas partes inferior e superior das folhas. Existe a presença inicial de sinais conhecidos como mancha azul, que na verdade é a presença do micélio do fungo (ARAÚJO e MENTEM, 2022).

Dentre as medidas de manejo para as pragas e doenças mais recomendadas para a cultura do algodão podemos citar rotação de culturas, tratamento de sementes, cultivares resistentes, controle biológico, aplicação de produtos fitossanitários como inseticidas, fungicidas e acaricidas. Dentre as medidas citadas a última é a mais utilizada entre os produtores. Assim, com a notável demanda destes defensivos e a maior frequência de pulverizações na cultura, esta prática tem representado uma fração significativa dos custos de produção reduzindo o lucro do produtor (ANSELMO *et al.*, 2012).

Atualmente existem alternativas de manejo que buscam reproduzir uma agricultura mais sustentável e que age de forma preventiva no manejo fitossanitário como a agricultura de precisão (AP). Esta técnica consiste na prática de manejo tecnológico que considera variações espaciais e temporais proporcionando aplicação localizada e com doses corretas de água, defensivos agrícolas, fertilizantes, corretivos e outros. Além disso, a AP permite o gerenciamento mais detalhado dos processos realizados desde o plantio à colheita. (BASSOI *et al.*, 2019). O Sistema de Posicionamento Global (GPS) e o Sistema de Informação Geográfica (SIG) são ferramentas capazes de monitorar a colheita, mapear atributos físicos e químicos dos solos e realizar a amostragem do solo dirigida (COELHO *et al.*, 2013).

Arelado a outras tecnologias, destaca-se o sensoriamento remoto (SR) que ajuda na obtenção de dados que apoiam a AP, por possibilitar a aquisição de imagens da superfície terrestre sem que haja contato físico com o objeto de estudo (PEREIRA e CASTRO, 2022). Essas imagens permitem gerar informações em tempo real para monitorar e detectar pragas e doenças em lavouras de algodão (ZHANG *et al.*, 2019).

A AP apresenta várias técnicas, mas o processamento de imagens obtidas por veículos aéreos não tripulados (VANT's) se destaca na agricultura por possibilitar a detecção de pragas, doenças, daninhas e auxilia no manejo da fertilidade do solo (MEDEIROS *et al.*, 2008; NUNES e LOPES, 2016). As imagens capturadas por VANT's são georreferenciadas de modo a permitir que a aplicação de produtos fitossanitários seja localizada exatamente onde a

praga foi visualizada. A coleta de dados ocorre com o uso de câmeras digitais que capturam imagens através do voo de veículos aéreos não tripulados (VANT's). A obtenção dessas imagens depende somente do operador da aeronave e por este motivo a aquisição de milhares de imagens pode ser feita de forma simples e com baixo custo (RODRIGUES e DE BARROS, 2018).

A tecnologia no campo surge como meio de receber e processar dados de forma mais eficiente de modo a auxiliar o manejo da cultura e otimizar tempo e recursos. Assim, nos últimos anos a Inteligência Artificial (IA) e o Aprendizado de Máquinas (AM) têm ganhado espaço nesse seguimento por possibilitar análise e processamento de dados de sensoriamento remoto a fim de auxiliar a interpretação e posteriormente a tomada de decisão. Holanda et al. (2021) citam no uso da AM na detecção de pragas e doenças por meio de dados radiométricos. Entretanto, poucos estudos abordam a AP e seu uso relacionado a obtenção e processamento digital de imagens para o algodoeiro. Essa ferramenta precisa ter seu uso ampliado a fim de otimizar o monitoramento para detecção de pragas e doenças da cultura por meio de imagens e auxiliar o produtor na tomada de decisão da melhor estratégia de controle.

## **2. OBJETIVOS**

### **Objetivo Geral**

Avaliar imagens de plantas sintomáticas visando detecção de pragas e doenças do algodoeiro.

### **Objetivos Específicos:**

- I) Obter imagens de plantas sintomáticas de algodoeiro;
- II) Analisar imagens de folhas de algodão lesionadas por pragas e doenças;
- III) Processar as imagens através do algoritmo de Redes Neurais Convolucionais Resnet 50 para auxiliar a detecção de pragas e doenças do algodoeiro com precisão superior a 80%.

### **3. REVISÃO DE LITERATURA**

#### ***3.1 A cultura do algodoeiro***

##### ***3.1.1 Histórico***

O algodoeiro é uma planta da família Malvaceae e dicotiledônea do gênero *Gossypium* que agrupa as espécies *Gossypium herbaceum* L., *Gossypium arboreum* L., *Gossypium barbadense* L., e *Gossypium hirsutum* L (SOUZA, 2017). Apesar de ser uma planta perene, atualmente é cultivada como planta de ciclo anual (SUASSUNA e MORELLO, 2017). A planta do algodoeiro é conhecida por ser uma das mais antigas, com domesticação aos 4.000 a.C anos pelos árabes, além do uso da fibra em toda Ásia Menor. Entretanto, referências arqueológicas denunciam que as espécies de algodão mais comuns encontradas no mundo têm origem na África Central. Nas Américas, há registros do uso do algodão pelos Incas no Peru a mais de 4.500 a.C. O algodão é produzido principalmente para fabricação de tecidos, é a fibra têxtil mais consumida no mundo, sua matéria prima é também usada pela indústria para fabricação de diversos produtos que vão desde cosméticos até alimentação humana e animal (LAMAS, 2020).

##### ***3.1.2 Importância da cultura***

A produção de algodão ocorre em diversos países e estima-se que aproximadamente 32 milhões de agricultores estejam envolvidos no cultivo em todos os cinco continentes (ONU, 2022). A produção mundial estimada é de 115 milhões na safra de 2022/2023 em aproximadamente 35 milhões de hectares com produtividade média de 1.230 toneladas por hectare (ABRAPA, 2023). Os maiores produtores da fibra são China com 28.000 milhões de fardos, seguida da Índia com 27.500 milhões, em terceiro lugar os Estados Unidos com 13.812 milhões de fardos e o Brasil como quarto maior produtor mundial com 13.000 milhões de fardos (USDA, 2022).

A área plantada com algodão no Brasil foi de 1,6 milhões em 2022, com produtividade de 1.593 quilos por hectare e produção de 2.550 toneladas por hectare da fibra (CONAB, 2022). Aproximadamente 89% dessa produção é exportada para Vietnã, China,

Turquia, Bangladesh, Paquistão e Indonésia totalizando 2,03 milhões de algodão (MINISTÉRIO DA ECONOMIA, 2022).

A produção do algodão no mundo varia de acordo com cada país, sendo que países como China e Índia tem sua produção voltada principalmente a pequenos produtores em escala familiar, mas com intensiva mão de obra. Por outro lado, países como Brasil, Estados Unidos e Austrália tem sua produção voltada a larga escala, mecanizada, com mão de obra tecnicada e gozam de boas práticas de manejo contra pragas, doenças e plantas invasoras (TELES e FUCK, 2016).

A cadeia produtiva do algodão se destaca no agronegócio brasileiro sendo uma das principais commodities. O crescimento da produção ocorreu em virtude do avanço da produção da cultura no cerrado, região onde estão os maiores produtores brasileiros (FERREIRA *et al.*, 2022). O algodão migrou do Sul e Sudeste para o Brasil central indo para a região Centro Oeste e Nordeste. Atualmente os estados do Mato Grosso, Bahia, Maranhão, Minas Gerais são responsáveis por cerca de 90% da produção nacional. Apenas o estado do Mato Grosso é responsável de cerca de 70% da produção do país, atingindo 1,9 milhões toneladas de algodão, seguido do Estado da Bahia chegou a produção de 577 mil toneladas, Goiás aproximadamente 49 mil toneladas, Maranhão 47 mil toneladas e Minas Gerais com 46 mil toneladas (ABRAPA, 2022).

### **3.1.1.3 Cultivo de algodão**

O sucesso do algodoeiro no cerrado deslanchou principalmente pelas pesquisas que buscaram variedades com melhor qualidade de fibra e adaptabilidade a região. O cerrado detém de clima, topografia plana e solos fisicamente favoráveis a produção, contribuindo com a expansão da cotonicultura no país (SANTANA *et al.*, 2020). Entretanto esse clima favorece o ataque de pragas e doenças e competição com plantas daninhas, fator limitante para o aumento da produtividade da cultura (SILVA *et al.*, 2019).

O algodoeiro é uma cultura acometida para diversas pragas que podem ser insetos ou ácaros que tendem a causar danos em diferentes partes da planta, da emergência até a colheita (IKEDA, 2019; MIRANDA, 2010). Dentro as principais pragas do algodoeiro destacam-se a tripses (*Thrips spp.*), pulgão (*Aphis gossypii*; *Myzus persicae*), cochonilha (*Phenacoccus solenopsis*), bicudo (*Anthonomus grandis*), mosca minadora (*Liriomyza huidobrensis*), o ácaro vermelho (*Tetranychus ludeni*), rajado (*Tetranychus urticae*) e branco (*Polyphagotarsonemus latus*), (DE ALMEIDA *et al.*, 2019).

As doenças do algodoeiro comprometem a produtividade e qualidade do produto podendo ser acarretadas por fungos, bactérias, nematoides e vírus. A ramulária, doença causada pelo fungo *Ramularia areola* se destaca por provocar lesões nas folhas, podendo acarretar danos estimados em 30% de produção da cultura no cerrado (EMRICH et al., 2018; LOPES et al., 2017).

É evidente que o algodoeiro é alvo de diversos ataques de pragas e patógenos, sendo de extrema importância implementar estratégias de manejo para reduzir a incidência e minimizar os danos causados por eles. Dentre estas medidas podemos citar a rotação de culturas, plantio na época correta, adoção de cultivares resistentes, controle biológico, eliminação de restos culturais, tratamento de sementes e controle químico (COTA et al., 2021). O controle químico com adoção de fungicidas, inseticidas e acaricidas continua sendo a principal estratégia empregada entre os produtores devido a facilidade de adoção e rapidez do resultado. Entretanto, o uso contínuo e irracional destes produtos pode ocasionar na contaminação do ambiente (TEIXEIRA et al., 2021). Para garantir a eficácia dos defensivos é necessário que o produtor respeite o intervalo entre as aplicações, doses recomendadas pelo fabricante e adotar boas medidas de tecnologia de aplicação (RIBEIRO e CASTILHO, 2018). Entretanto, sozinho o controle químico não proporciona o controle ideal a longo prazo, sendo necessário adotar o manejo integrado.

O Manejo Integrado de Pragas (MIP) é uma alternativa imprescindível para a agricultura que visa associar diferentes medidas de controle a fim de manter a população das pragas abaixo do nível de dano econômico (NASCIMENTO et al., 2017). O nível de dano econômico corresponde a densidade populacional da praga capaz de causar prejuízos de valor igual ao custo do seu controle (RILEY, 2008).

O monitoramento de pragas e doenças, prática essencial do MIP, consiste em observar e identificar a presença de determinada praga ou doença, a expressão dos sintomas e sinais. Associando-as com a fenologia, suscetibilidade e idade da planta, seu objetivo é avaliar o nível de dano econômico com o intuito de determinar o momento certo de aplicação de defensivos (SANTOS FILHO et al., 2008).

### **3.2 Agricultura de Precisão**

O Brasil é um dos maiores produtores de alimento no mundo sendo altamente competitivo e tem enorme importância para o crescimento do Produto Interno Bruto (PIB)

nacional, além de ser responsável pela geração de empregos. No ano de 2022 o agronegócio contribuiu para fornecer 84.043 empregos para o país, o Cepea (Centro de Estudos Avançados em Economia Aplicada) estimou que a participação do agronegócio no PIB nacional neste mesmo ano chegou a 24,8 %. (CEPEA, 2022; FPA, 2022). O agronegócio brasileiro bateu recorde de exportações no acumulado do ano, chegando à marca de US\$ 136,10 bilhões, com aumento de 33% comparado ao mesmo período do ano de 2021 (Correio Braziliense, 2022).

Dentro desse contexto a agricultura brasileira tem grande responsabilidade com a geração de empregos no país e com a demanda mundial por alimento, visto que em 2022 a população mundial chegou à marca de 8 bilhões de pessoas (ONU, 2022). Para aumentar a produtividade das lavouras sem aumentar a área plantada é necessário aprimorar os sistemas de produção através de novas tecnologias. A racionalização das aplicações de fertilizantes, fungicidas, inseticidas, acaricidas e herbicidas, com a quantidade exata e no local preciso, se torna possível graças a AP (MOLIN, 2017).

A AP, traduzida do termo "Precision Farming" ou "Precision Agriculture" consiste na junção de tecnologias que permite o aprimoramento dos sistemas de produção através da variabilidade espacial e temporal das áreas de cultivo (RESENDE e COELHO, 2017). Esta ciência pode ser entendida como um sistema de gestão baseada na variação espacial e temporal do campo (INAMASU e BERNARDI, 2014) com a finalidade de produzir de forma sustentável aumentando a economia da produção. Para isso existem ferramentas oriundas da AP que são capazes de garantir o manejo específico para a exigência de cada talhão, reduzindo os efeitos negativos do ambiente (ANTONINI *et al.*, 2018).

Existem algumas tecnologias que se destacam na AP como os sistemas de posicionamento global (SPG ou GPS) e de informações geográficas. O monitoramento das áreas ("Crop Scouting"), sensoriamento remoto, imagens aéreas obtidas através de VANT's e de satélites, aplicação em taxa variável, manipulação e recuperação de dados e diversos tipos de sensores (ARTUZO *et al.*, 2016; MIRANDA *et al.*, 2017; SPERANZA *et al.*, 2017). Além do monitoramento dos campos, a AP é direcionada para as máquinas agrícolas, como semeadoras, colheitadeiras, pulverizadores, entre outras máquinas com computadores de bordo posicionados em suas cabines e piloto automático.

Apesar de inúmeras vantagens, existe algumas limitações a adoção da AP, como a resistência por parte dos produtores em utilizar as ferramentas da AP pelo alto custo de implantação e a falta de informação e treinamento profissionais e produtores (DA SILVA e SILVA-MANN, 2020).



### **3.2.1 Veículo aéreo não tripulado (VANT)**

Os (VANT's) inicialmente eram atribuídos em atividades civis e militares, sendo que o início de sua prática ocorreu na Primeira Guerra Mundial no ano de 1917 (SLONGO *et al.*, 2017). Através do projeto Acauã, desenvolvido pelo Centro Tecnológico Aeroespacial (CTA) na década de 80, o Brasil iniciou seu contato com os VANT's (JORGE e INAMSU, 2014).

O VANT pode ser pilotado remotamente ou de forma automática por meio de coordenadas definidas. Além do uso militar, seu potencial tem sido explorado no Brasil e em outros países nas áreas da silvicultura, agricultura, arqueologia e diversos setores (BALLESTEROS e LORDSLEEM JUNIOR, 2020).

No setor agrícola os VANT's têm aplicação em missões de pulverização e monitoramento, permitem a captura de imagens mais próximas e com melhor resolução das lavouras. Também proporciona maior sensoriamento da área em maior frequência temporal. Além de portar um receptor GNSS integrado que viabiliza a ação precisa em locais com maior exigência (SOELA *et al.*, 2020).

A aquisição das imagens por meio dos VANT's, torna possível mapear lavouras e avaliar o estado nutricional e hídrico das plantas, detectar plantas invasoras, níveis de erosão, e a presença de pragas e doenças. O aumento da manipulação de VANT's para práticas de monitoramento vem crescendo graças ao emprego de novas tecnologias desenvolvidas para atender as necessidades agrícolas (CHIACCHIO *et al.*, 2016). Os sensores mais usuais nas áreas de exploração agrícola no Brasil, são sensores de índice de vegetação por diferença normalizada (Normalized Difference Vegetation Index NDVI), e de infravermelho (SAMPAIO *et al.*, 2020). Essas ferramentas permitem a percepção de alterações na vegetação.

### **3.2.2 Processamento digital de imagens**


A identificação de pragas e doenças nas áreas de cultivo de forma rápida desperta interesse nos agricultores por reduzir perdas pelo avanço dos danos e conseqüentemente maior tempo de qualidade. Assim a possibilidade de detectar lesões causadas por insetos, ácaros e microorganismos patogênicos, observadas em folhas através de imagens despertam a atenção de técnicos e produtores. Por meio da execução do processamento e análise de imagens

intermediada por softwares e algoritmos é possível aumentar a eficiência desta prática (COSTA *et al.*, 2017).

A utilização de Visão Computacional e AM auxilia na da causa das injúrias e também do nível de dano causado por elas de maneira precisa e acurada (PACIFICO, 2020). Sistemas disponibilizados através de Application Programming Interface (APIs), tem como aplicabilidade encontrar padrões nas imagens, como, forma, textura, cor ou outros elementos que são objetivos do estudo por meio do processamento digital de imagens (KAUFAN e VILAS BOAS, 2019).

O processamento digital de imagens (PDI), pode ser dividido em cinco etapas: aquisição de imagens, pré-processamento, segmentação, extração de atributos e classificação. (Figura 1).

**Figura 1- Componentes estruturais de um sistema de processamento digital de imagens.**



A aquisição das imagens pode ser realizada por câmeras de aparelhos celulares, tablets, câmeras digitais, VANT´s entre outros. Com o objetivo de melhorar a imagem, corrigir algum defeito proveniente de sua aquisição ou realçar detalhes importantes para a análise é realizada a fase de pré-processamento. Já na fase de segmentação, busca-se separar as regiões de interesse da imagem, das demais regiões. No caso de detecção de doenças foliares, na etapa de segmentação separa-se a amostra foliar do fundo da imagem (MARGIOTTI e SILVA, 2018). Este processo ajuda a diminuir o gasto computacional uma vez que é trabalhado somente nas regiões de interesse da imagem.

A extração de atributos é necessária para representar as características relevantes dos dados de entrada antes das imagens serem utilizadas para algoritmos de aprendizado de máquinas e processamento de imagens. Isso pode envolver técnicas baseadas em texturas, formas, cores, entre outros atributos específicos da imagem. O objetivo é capturar os recursos mais discriminantes e informativos que ajudarão a diferenciar as classes de interesse. No estudo realizado por Ponti *et al.* (2016), foram utilizados seis atributos para representar texturas, sendo eles: máxima probabilidade, dinâmica, contraste, uniformidade energia, homogeneidade e

entropia. Esses atributos foram computados usando uma matriz de coocorrência, que considera os valores da imagem em relação a um pixel de referência e seus vizinhos (PONTI *et al.*, 2016).

Já na etapa de treino/classificação, um algoritmo ou modelo de aprendizado de máquina é treinado para classificar as imagens com base nas características extraídas. Dependendo do problema, diferentes algoritmos podem ser usados, como Máquinas de Vetores de Suporte (SVM), Redes Neurais e outros e Redes Neurais Convolucionais (GONZALEZ e WOODS, 2010).


### ***3.3. As redes neurais artificiais e convolucionais***

As redes neurais artificiais (RNA) foram desenvolvidas no campo da ciência da computação (1943) por McCulloch e Pitts, mas seu uso como solução para problemas de reconhecimento de padrões começou a ganhar destaque na década de 1960. Desde então, as RNA têm sido amplamente utilizadas em diversas áreas que agrupam algoritmos de reconhecimento de padrões, processamento de máquina e inteligência artificial. Estes algoritmos possuem técnicas computacionais inspirados na estrutura neural do cérebro para construir modelos matemáticos que adquirem conhecimento por meio da experiência (RAUBER, 2005). Uma das principais características das redes neurais construídas é sua capacidade de aprender a partir de exemplos e generalizar o conhecimento adquirido, obtido em modelos não lineares. Essa capacidade torna as redes neurais altamente eficientes na análise espacial.

#### ***3.3.1 Perceptron- Rede neural de camada única***

O perceptron é simples, mas importante para o entendimento claro de como funciona uma rede neural. Ele recebe um conjunto de entradas, atribui pesos a essas entradas e produz uma saída com base em uma função de ativação. Essa função determina se o perceptron ativará ou não a saída com base nos valores ponderados das entradas. Ele pode receber inúmeras entradas,  $x_1$ ,  $x_2$ ,  $x_3$  e irá produzir somente uma saída (ROSENBLATT, 1958; GOODFELLOW, 2016) (Figura 2).

Figura 2- Exemplo do funcionamento de um perceptron para classificação linear.




Fonte: VERMA e SINGH, 2015 p 3. Adaptado.

O perceptron é utilizado para aprender funções de classificação, sendo capaz de separar dados em dois conjuntos linearmente separáveis. No entanto, é importante ressaltar que se os dados não forem linearmente separáveis, o algoritmo do perceptron não convergirá para uma solução e os dados não serão classificados corretamente. Por outro lado, se os dados forem linearmente separáveis, o algoritmo perceptron pode encontrar um conjunto de pesos que possam classificar corretamente os dados. Nesse caso, o perceptron ajusta e atualiza independentemente os pesos com base na diferença entre a saída prevista e a saída correta. Essas atualizações continuam até que os dados sejam classificados corretamente ou um critério de parada seja atendido (figura 3) (CROSS, HARRISON, KENNEDY, 1998).

A saída do neurônio é determinada pela comparação da soma ponderada das entradas com um valor limiar (threshold), sendo 0 ou 1. Tanto os pesos quanto o threshold são parâmetros do neurônio, que são ajustados para modificar o comportamento do perceptron.


**Figura 3- Exemplo do funcionamento de um perceptron para classificação linear.**



Fonte: CROSS, HARRISON, KENNEDY, 1995, P 1076.

No final da década de 1950, na Universidade de Cornell, Rosenblatt desenvolveu uma rede neural, composta por vários neurônios conhecida como rede perceptron. Essa rede foi projetada para funcionar como um discriminador linear. A rede perceptron consiste em neurônios organizados em camadas, permitindo a realização de tarefas de classificação e tomada de decisão (figura 4) (COPPIN, 2013).

**Figura 4- Rede Neural Perceptron.**



Fonte: TAFNER, 1998. Adaptado.

Redes neurais artificiais são modelos computacionais inspirados na estrutura e funcionamento do sistema nervoso humano. Elas são projetadas para adquirir conhecimento e

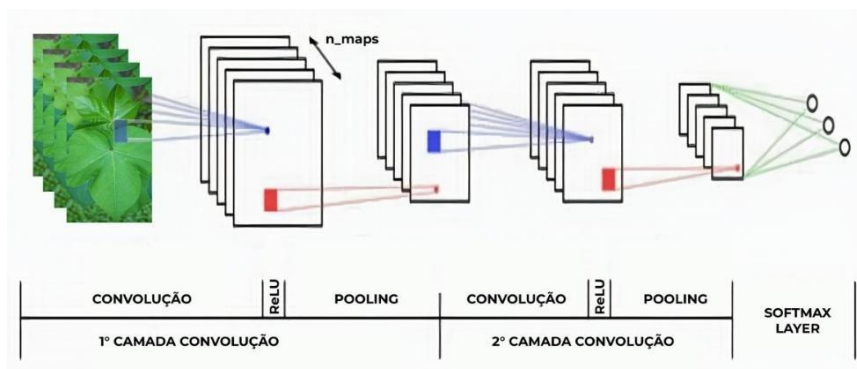
aprender a partir da experiência (FLECK *et al.*, 2016). Um caso específico de redes neurais artificiais são as redes neurais convulsionais que são apresentadas a seguir.

### 3.3.2 Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais, conhecidas como ConvNets ou CNNs são muito eficazes na captura de recursos de imagem porque pode identificar padrões hierárquicos locais nas imagens. Cada camada convolucional aplica filtros convolucionais aos dados de entrada, resultando em mapas de recursos que focam em diferentes aspectos da imagem. Esses mapas de recursos são propagados para camadas subsequentes, permitindo que a rede aprenda representações cada vez mais complexas. Mesmo as CNNs provando serem eficientes e se tornando o novo padrão em visão computacional, este modelo de rede neural requer um grande número de amostras rotuladas para atingir uma classificação satisfatória (ARAÚJO *et al.*, 2017).

A arquitetura básica de uma CNN é mostrada na figura 5. Uma CNN funciona basicamente realizando várias convoluções em cada camada da rede, de forma que as camadas convolucionais atuam como uma espécie de extratores de características.

**Figura 5- Diagrama de uma Rede Convolucional.**



Fonte: GRINBLAT *et al.*, 2016. Adaptado.

#### 3.3.2.1. Alguns componentes de uma CNN

#### 3.3.2.2 Camada Convolucional

Uma CNN é um tipo de modelo de aprendizado profundo especialmente projetado para processar dados como imagens. Ela é chamada de convolucional devido à operação central

que realiza, chamada de convolução. A convolução é uma operação fundamental nas CNNs, ela desempenha um papel central no processamento de dados de entrada, como imagens e é responsável por extrair características relevantes da imagem (HOLANDA, *et al.*, 2021).

Os *kernels* são um conjunto de parâmetros que são aprendidos durante o processo de treinamento da rede. Esses *kernels* agem como pequenas janelas ou áreas que executam operações na imagem. A cada passo, cada elemento do filtro é multiplicado pelo elemento naquele ponto na mesma posição na área onde o *kernel* é aplicado. Eventualmente, os resultados dessas multiplicações são adicionados para produzir um único valor na saída, este valor será o pixel correspondente na imagem filtrada (RODRIGUES, 2019).

### 3.3.2.3 Função de ativação

Camadas convolucionais geralmente executam outras operações para reduzir o espaço de características. Existem diversas funções de ativação, como a softmax, tanh, sigmoide, entretanto a mais indicada é a função ReLu (unidade linear retificada) que pode ser traduzida como “retornar”, pois mapeia os valores negativos para zero e mantém os valores positivos inalterados, essa propriedade evita cálculos difíceis, além de não causar grandes diferenças de acurácia em comparação com outras funções de ativação (ALVES, 2018).


Esta função é uma função não linear simples que retorna 0 se o valor de entrada for negativo e se for 0 ou positivo deve-se manter o valor de entrada. Se for zero, mantemos o valor de entrada ( $F(x)$ ) do nível anterior, mas também obtemos o valor de entrada  $x$  para essas funções (SOUZA *et al.*, 2020). Ao usar a função ReLU em redes neurais profundas, os neurônios ativados por ela passam adiante os valores positivos para as secundárias, enquanto os valores negativos são zerados.

### 3.3.2.4 Camada de Pooling

Uma camada de pooling, também conhecida como camada de agrupamento tem como objetivo descomplicar a informação da camada anterior. A camada de pooling opera independentemente em cada mapa de características geradas pelas camadas convolucionais. Ela agrupa localmente as informações, substituindo um conjunto de valores por um único valor representativo.

Na camada de pooling de uma rede neural convolucional, é selecionada uma unidade de área, como um filtro 2x2, que se move sobre toda a saída da camada anterior. Essa unidade é responsável por resumir as informações contidas na área em um único valor representativo. Por exemplo, se a saída da camada anterior tiver dimensões 24x24, a camada de pooling reduzirá essas dimensões para 12x12. Durante o processo de pooling, a unidade de área desliza pela saída da camada anterior em intervalos definidos, como uma janela deslizante. Em cada posição, a unidade de área aplica uma operação, podendo ser max pooling ou average pooling, para obter o valor representativo daquela região (WU, 2017). Em seguida é possível observar uma camada com operação de max pooling na figura 6.

**Figura 6- Camada pooling utilizando kernel 2x2.**



No final de uma camada convolucional, uma sequência de camadas neurais geralmente é usada e vinculada (*fully-connected*) com todas as ativações da camada anterior, (LECUN *et al.*, 2015).

### 3.3.2.5. Camada totalmente conectada (*fully-connected*)

Essa camada é colocada ao final da rede, ela é totalmente conectada na camada em que todos os neurônios na camada anterior estão conectados a cada neurônio na camada atual. Isso permite que as informações sejam coordenadas de forma global, levando em consideração todas as características da camada anterior.

Quando se trata de redes convolucionais, a primeira camada convolucional geralmente é projetada para detectar características com padrões mais simples. À medida que avançamos para planos convolucionais subsequentes, os filtros se tornam mais especializados e são capazes de detectar características mais complexas. Isso ocorre porque as camadas convolucionais e de *pooling* são empilhadas para extrair gradualmente características com um nível de abstração maior (VARGAS, PAES, VASCONCELOS, 2016).




Após a camada totalmente conectada, o último passo geralmente é a camada de classificação. A camada de classificação é responsável por mapear as características extraídas pelas classes anteriores em probabilidades associadas a cada classe do problema de classificação (RUSSAKOVSKY *et al.*, 2016).

### 3.4 A rede neural convolucional ResNet50.

Dentre as diversas arquiteturas de redes neurais, neste trabalho utilizamos a rede ResNet 50. Esta arquitetura de rede neural venceu o concurso o ILSRVC de 2015 (ImageNet Large Scale Visual Recognition Challenge). As ResNets são formadas por conexões residuais de atalho que efetivamente facilitam a implementação de arquiteturas neurais mais profundas com melhor desempenho sem aumentar a complexidade computacional.

A ResNet é composta por várias camadas, sendo que a versão ResNet-50 possui 50 camadas no total. A arquitetura da ResNet é baseada em blocos residuais, conhecidos como *Residual Blocks*. Esses blocos residuais têm como objetivo facilitar o treinamento de redes neurais mais profundas. A ideia por trás deles é possibilitar a entrada original ( $x$ ) de um bloco passe por uma série de operações, como convolução, ativação ReLU e outra convolução (Figura 7).

Figura 7- Aprendizagem Residual: Um bloco de construção.

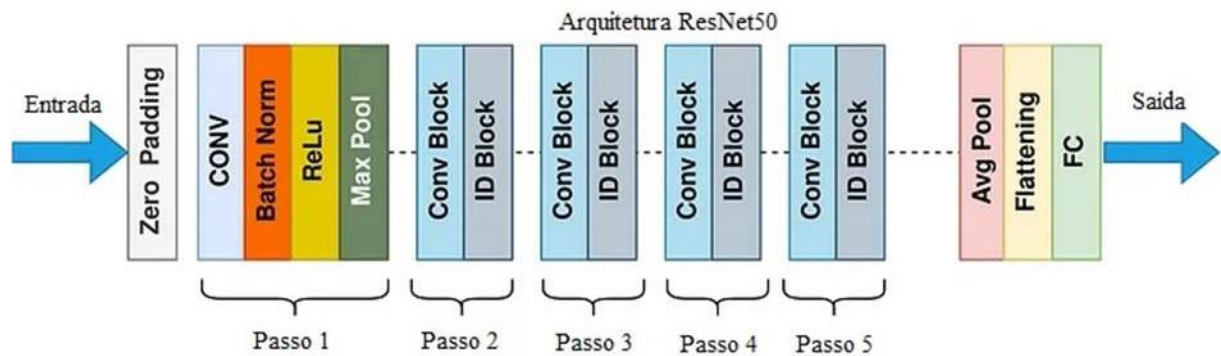


Fonte: HE *et al.*, 2016. Adaptado.

Portanto, as ResNets mostram que o mapa residual pode ser mais facilmente otimizado com uma mudança no espaço de entrada. A ResNet 50, possui 50 camadas e usa convoluções  $1 \times 1$  que diminui os parâmetros e multiplicações de matrizes. Isso permite que cada camada seja treinada mais rapidamente, utilizando uma pilha de 3 camadas no lugar de uma

pilha de 2 camadas (MUKHERJEE, 2022). Na figura 8 é possível observar como a Resnet 50 funciona.

Figura 8- Modelo de uma arquitetura Resnet 50



Fonte: MUKHERJEE, 2022. Adaptado.

### 3.5 Alguns trabalhos atuais em inteligência artificial

Moreira *et al.* (2020) utilizaram o método da Lógica *Fuzzy* (difusa) como ferramenta para a detecção da septoriose no tomateiro. A lógica difusa pode ser aplicada a diversos problemas, uma vez que foi desenvolvida para apontar se algo é totalmente falso ou totalmente verdadeiro, sendo 0 correspondente ao valor falso e 1 correspondente ao valor verdadeiro. Os testes foram realizados através de dados coletados, sendo os sintomas dispostos e a escala de notas variando de 0 a 6, sendo que de 0 a 3,9 correspondente a fase leve da doença, 4 a 5 mediana e mais de 5 torna-se grave.

O algoritmo *Random Forest* disponível no aplicativo WEKA (*Waikato Environment for Knowledge Analysis*), detectou a doença antracnose no cultivo de pimentão. O algoritmo reúne grupos de árvores de decisão geradas a partir do treinamento, em que o produto do algoritmo fornece resultado de todas os subconjuntos de árvores (DE SOUSA e DE BRITO, 2020).

Locatelli *et al* (2021) propôs em seu trabalho identificar fitotoxidez de Saflufenacil em mudas de Café Conilon utilizando RNAs. O algoritmo utilizado foi o Resilient Propagation com 3.000 ciclos. Os parâmetros fisiológicos e biométricos analisados demonstraram ser indicadores confiáveis do estado das plantas. Foi possível obter estimativas precisas da fitotoxidez do herbicida utilizando esses parâmetros, com a maioria das estimativas de erros de modelagem abaixo de 5%.

Neto *et al.* (2019) utilizaram as Redes Neurais Convolucionais (CNNs), para detectar e contar laranjas no campo a fim de estimar a produção e auxiliar os agricultores na tomada de decisão no momento da comercialização destes produtos. As CNNs são redes neurais especializadas que usam a convolução como extrator de características no processamento visual de imagens. Esta ferramenta atua de forma semelhante ao processo biológico da visão, por este motivo as CNNs estão sendo aplicadas na detecção de imagens (VARGAS *et al.*, 2016).

Existe uma limitação em encontrar o melhor algoritmo que identifique de forma prática e rápida as lesões causadas por pragas e fungos. Tendo em vista que a maioria dos testes realizados tiveram imagens registradas em ambiente controlado ou em número reduzido de imagens. Por esta razão o trabalho utilizou as CNNs para detectar pragas e doenças no algodoeiro por alcançar bons resultados em trabalhos relacionados.

## 4. MATERIAIS E MÉTODOS

### 4.1 Obtenção de imagens

As imagens utilizadas neste trabalho foram capturadas na fazenda Futura, propriedade produtora de grãos e algodão, localizada no município de Brasilândia de Minas, noroeste mineiro. Essa região é caracterizada pelo bioma de cerrado, com clima tropical Aw com estações bem definidas. Durante os meses de outubro a abril prevalece um clima quente e chuvoso, enquanto nos meses de maio a setembro ocorre uma estação fria e seca.

As imagens foram capturadas durante os meses de abril e maio de 2022 em cinco diferentes pivôs de lavouras de algodão. A seleção desses pivôs ocorreu após consulta aos agrônomos da fazenda que identificaram pragas e doenças presentes em cada área. As imagens foram registradas no campo, sem remover as folhas das plantas ou retirar as plantas do solo. Esse método dificultou a obtenção de um padrão consistente de distância e iluminação, devido às circunstâncias em que as imagens foram obtidas. Além disso, as plantas estavam em diferentes fases de desenvolvimento, devido a diferentes datas de plantio e variedades utilizadas, conforme a tabela 1. Essa variabilidade resultou em plantas de algodão com tamanhos e estádios de florescimento variados. Em todas as áreas destinadas à aquisição das imagens, foram realizadas várias pulverizações preventivas e de controle de pragas e doenças.

**Tabela 1- Informações sobre as cultivares, data de plantio e hectares plantados com algodão.**

<b>Pivô</b>	<b>Cultivar</b>	<b>Data de plantio</b>	<b>Hectares</b>
<b>2</b>	DP 1786 RF	25/01/2022	100
<b>4</b>	DP 1786 RF	29/01/2022	65
<b>9</b>	DP 1857 B3 RF	22/01/2022	49
<b>9</b>	DP 1866 B3 RF	21/01/2022	25
<b>10</b>	FM 912GLTP RM.	23/01/2022	55
<b>11</b>	FM 974GLT	21/01/2022	23

As imagens foram registradas por meio da câmera do celular Redmi Note 8 da Xiaomi, com quatro câmeras traseiras com tecnologia quad-pixel, que combinadas resultam em um pixel, sendo que a câmera conta com uma resolução de 48 megapixels (MP). A tecnologia do aparelho permite a realização de diversos ajustes, como HDR resultando em imagens mais nítidas além disso, é possível ajustar o foco, zoom, cronômetro, entre outras configurações. Porém, o único ajuste realizado para registro das imagens foi a redução da proporção da foto

que foi de 1:1 com o propósito de obter imagens quadradas. para obter uma classificação satisfatória. Foram capturadas em campo aproximadamente 1.500 imagens.

#### 4.2 Pré-processamento das imagens e classificação das pragas e doenças

As imagens obtidas foram analisadas visualmente e foi determinado quais doenças e pragas predominavam. Entre as lesões causadas por pragas, foi possível observar a presença de tripses, ácaro e larva minadora. Apenas as doenças mancha-alvo e manchas de ramulária foram observadas na lavoura, entretanto mancha alvo não foi significativa para a realização do treinamento com o algoritmo por não ter um número significativo de imagens com lesões causadas por esta doença. Após a análise, as imagens foram separadas em pastas com a denominação da praga ou doença incidente. Dentro de cada pasta as imagens foram subdivididas em imagens para treino e imagens para teste.

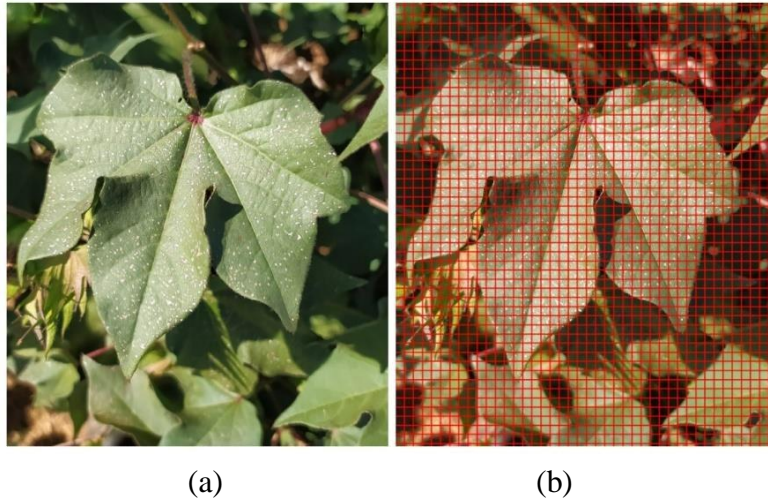
A classificação e separação das imagens reduziu o banco de dados para o treinamento e teste no software. As imagens de pragas no campo foram mantidas sem qualquer tipo de tratamento como redução de ruídos, aplicação de filtros ou qualquer outra melhoria. Essa abordagem foi adotada com o objetivo de poder utilizar as imagens exatamente como foram capturadas de forma a manter fidelidade à situação real da lavoura.

**Tabela 2- Número de imagens utilizadas no teste.**

Imagens observadas	Nome comum	Número de imagens.
<i>Thrips spp</i>	Tripses	79
<i>Tetranychus urticae</i>	Ácaro rajado	79
<i>Liriomyza huidobrensis</i>	Mosca minadora	79
<i>Ramularia areola</i>	Ramulária	79
Fundo	Imagem com fundo	79
Folha sadia	Folha sadia	79


Entretanto no momento de classificação muitas imagens foram descartadas por não ser possível identificar o tipo de lesão presente na imagem e não estarem aptas ao treino no software, restando apenas 960 no banco de dados. Depois de classificadas e separadas, as imagens do banco de dados foram divididas em subimagens de tamanho 102 x 102 pixels (Figura 8).

**Figura 9- Grade de formação de subimagens**  
**(a) Folha sintomática (b) Folha quadriculada.**



Essas subimagens foram agrupadas dentro de suas pastas e classificadas como ácaro FA1 (2a), folhas saudias FLS1 (2b), mosca minadora FMM1 (2c), ramulária FMR1 (2d), tripes FT1 (2e), subimagens que apresentavam foi classificado como IF3 (f) e as imagens que não se enquadravam em nenhuma dessas classes foram descartadas (Figura 10).

**Figura 10- Exemplo de subimagens utilizadas.**



Para o treinamento do algoritmo 70% das imagens do banco de dados foram utilizadas e 30% das imagens foram reservadas para validação. Ea fase de teste e validação do algoritmo.


### 4.3 Aprendizado e classificação pelo algoritmo

Para a fase de aprendizado e classificação das imagens, foi utilizado o algoritmo de Redes Neurais Convolucionais Profundas (CNNs), em que o aprendizado é feito por meio de treinamento e a classificação é o teste propriamente dito.

O algoritmo foi implementado usando o software Matlab R2018a (Mathworks), instalado num computador HP Z800 com dois processadores Intel® Xeon® X5650 Cache 12M, 2,66 GHz, 6.40 GT/s Intel® QPI, 128 Gb Ram, placa de vídeo Nvidia Quadro FX 3800 com base no sistema operacional Windows 10.


Os dados são inseridos no algoritmo e divididos em arquivos para treinamento e arquivos para validação. Criando pastas e subpastas com cada uma das classes. Exemplo a seguir (figura 11).

**Figura 11- Rótulos de saída do algoritmo**



O algoritmo rotulou automaticamente as imagens com base do nome das pastas. Durante o treinamento, a CNN irá extrair características distintas entre as classes para que posteriormente consiga distingui-las no momento da validação. Uma vez que o modelo foi treinado, novas imagens serão utilizadas para que a arquitetura retorne com a classificação e posterior validação do método. A camada de saída contendo seis classes, sendo elas tripes, ácaro, minadora, ramulária fundo e folha sadia (figura 12).

**Figura 12-Teste com apenas uma entrada e gerando 6 saídas.**



#### 4.4 Métricas de avaliação

Uma matriz de confusão ou matriz de erro foi gerada para o algoritmo de Redes Neurais Convolucionais, essa matriz é usada para definir os parâmetros ideais e gerar um modelo que possa prever e inferir classes dentro da área de estudo. A matriz de confusão é formada por linhas e colunas, as colunas vão determinar a verdade absoluta, ou seja, o resultado obtido, enquanto que as linhas irão mostrar a classe da imagem. Ela representa o resultado do desempenho do modelo preditivo, dividindo os resultados em quatro quadrantes.

Essa matriz é uma ferramenta importante para avaliar a precisão e o desempenho geral de um modelo de aprendizado de máquina, permitindo uma análise mais detalhada dos erros e acertos do algoritmo. Com base na matriz de confusão, várias métricas de avaliação podem ser recorrentes, como acurácia, sensibilidade, especificidade, exatidão global, índice Kappa e análise de cada classe.

Na tabela a seguir é possível observar os quadrantes de uma matriz de confusão. Sendo quatro quadrantes, o primeiro quadrante para verdadeiros positivos VP, quando demonstra a classe que foi prevista corretamente. O quadrante segundo para falsos positivos FP quando a classe foi prevista de forma incorreta, quadrante 3 para falsos negativos FN ocorre quando uma classe deveria ser prevista é prevista incorretamente e o quarto quadrante o verdadeiro positivo VN ocorre quando a classe que não deveria ter sido prevista é prevista de forma correta.



Tabela 3- Estrutura de uma matriz de confusão.

		Valor Predito	
		Sim	Não
REAL	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: (FERRARI e SILVA, 2017) adaptado.

A exatidão global ( $EG$ ) é obtida pela soma das entradas da diagonal da matriz de confusão ( $x_{ij}$ ), ou seja, a somatória dos acertos, pelo número total de amostras relacionadas ( $n$ ).

Equação 1

$$EG = \frac{\sum_{i=1}^m x_{ij}}{n}$$

Portanto, ( $m$ ) é o número de linhas da matriz de confusão; ( $x_{ij}$ ) são as informações da diagonal da matriz de confusão; e ( $n$ ) é o número total de pontos amostrados.

O índice kappa é uma medida estatística utilizada para avaliar a concordância ou a confiabilidade entre observadores ou avaliadores em relação a uma classificação ou um julgamento. Ele é especialmente útil quando se trabalha com dados categóricos ou qualitativos, este coeficiente pode ser baseado nos elementos da matriz de confusão. O índice Kappa pode ser obtido por meio da equação 2 a seguir:

Equação 2

$$K = \frac{n \sum_{i=1}^m x_{ij} - \sum_{i=1}^m x_{i*} x_j}{n^2 - \sum_{i=1}^m x_{i*} x_j}$$

De forma semelhante a fórmula de exatidão global; ( $n$ ) é o número total de pontos amostrados, ( $m$ ) é a somatória do número de classes; ( $x_{ij}$ ) é o valor da linha ( $i$ ) e da coluna ( $j$ ); ( $x_{i*}$ ) é o total da linha  $i$  e ( $x_j$ ) é o total da coluna  $j$  e  $K$  é uma estimativa do coeficiente Kappa.

O índice kappa mede a concordância além do acaso, levando em consideração a concordância observada e a correspondência esperada por acaso. Ele varia de -1 a 1, onde pode ser interpretado através de uma tabela sugerida por LANDIS e KOCH (1977).

**Tabela 4- Interpretação dos valores da estatística Kappa**

Índice Kappa	Desempenho
< 0	Muito Ruim
0,01 à 0,20	Fraco
0,21 à 0,40	Razoável
0,41 à 0,60	Moderado
0,61 à 0,80	Bom
0,81 à 0,99	Quase perfeito

Fonte: (LANDIS e KOCH, 1977). Adaptado.

Além da avaliação do desempenho geral, também foi analisado o comportamento dos classificados para cada classe, utilizando medidas como sensibilidade (recall), especificidade, precisão e F-score. Com as equações descritas a seguir:

**Tabela 3- Métricas de avaliação.**

Medidas de desempenho	Equação
Sensitividade (recall)	$TP/(TP+FN)$
Especificidade	$TN/(TN+FP)$
Precisão	$TP/(TP+FP)$
F-Score	$(2*Precisão*Recall)/(Precisão+Recall)$

## 5. RESULTADOS E DISCUSSÃO

O algoritmo de Redes Neurais Convolucionais (CNNs ou ConvNet) resnet 50 empregado com aprendizado supervisionado alcançou o resultado desejado na tarefa de classificar as imagens de folhas lesionadas do algodoeiro. A CNN obteve uma acurácia de 84,6% para esse propósito.

O resultado obtido para exatidão global abaixo (tabela 6) de 90% demonstra que o algoritmo proposto com arquitetura Resnet 50 é capaz de detectar com precisão as lesões nas imagens utilizadas para treiná-lo. No entanto, é importante lembrar que a exatidão global é apenas uma métrica geral e pode não refletir a precisão em cada classe específica de pragas e doenças. Com relação ao índice Kappa, quanto mais próximo de 1, maior é o grau de concordância entre as projeções do modelo e as classificações reais, indicando um desempenho muito confiável na detecção de pragas e doenças no algodoeiro por análise de imagens. Isso sugere que o modelo tem uma capacidade significativa de identificar corretamente a ocorrência de pragas e doenças.

Apesar da consideração da distribuição dos dados, realizou-se uma análise de desempenho das classes listadas. Essa avaliação foi baseada em medidas derivadas da matriz de confusão, como a exatidão global e o índice Kappa.

**Tabela 6- Resultados das métricas de avaliação.**

<b>z</b>	<b>Exatidão Global</b>	<b>Kappa</b>
<b>CNN</b>	95,96%	0,845981

Na análise do desempenho por classe, constatou-se que a classe tripes (FT1) apresentou o maior desempenho em comparação com as outras, enquanto a classe ramulária teve o menor desempenho entre elas. Essa observação é evidenciada pela análise da matriz de confusão apresentada na Tabela 7:

A classe ramulária teve o menor desempenho dentre todas as classes, além disso sete das setenta e nove imagens de ramulária foram classificadas como imagens de folha sadia. A fase inicial da doença pode ser associada a imagens sadias, essa classificação pode ter acontecido de forma errônea porque as lesões da doença apresentam-se inicialmente com manchas angulares e de cor verde claro, posteriormente manchas brancas e amarelas (SANTOS, 2015).

Tabela 7. Matriz de Confusão

	Fundo	Tripes	Mosca Minadora	Ácaro	Ramulária	Folha Sadia
Fundo	70	1	2	1	5	0
Tripes	1	74	3	0	1	0
Mosca Minadora	5	1	61	2	7	3
Ácaro	0	0	2	72	4	1
Ramulária	1	5	5	6	55	7
Folha sadia	1	1	2	2	4	69
			Acurácia			
			84,6%			

Considerando a análise de desempenho para cada classe vemos que em todas as classes a taxa de verdadeiro positivo está acima da média de outros autores. Isso implica em um alto valor, indicando que o algoritmo está acertando na detecção das lesões de folhas do algodoeiro em uma proporção significativa dos casos (tabela 8).

Tabela 8- Análise de desempenho para cada classe.

Classes	TP	FP	FN	TN
Fundo	89%	10%	11%	90%
Tripes	94%	10%	6%	90%
Mosca Minadora	77%	19%	23%	81%
Ácaro	91%	13%	9%	87%
Ramulária	70%	28%	30%	72%
Folha Sadia	87%	14%	13%	86%

É possível observar que as classes ramulária e mosca minadora, apresentaram menor desempenho na classificação de verdadeiro positivo em relação as demais, isso sugere que essas duas classes possuem alguma semelhança entre si, o que pode ter causado confusão no processo de aprendizado do algoritmo. Em seu estudo Barbedo (2018) aponta que determinadas situações, alguns distúrbios ou condições podem gerar sintomas visualmente semelhantes, o que pode dificultar o reconhecimento do algoritmo usando apenas imagens RGB simples, mesmo quando o modelo está bem treinado. Em tais situações, a informação visual disponível nas imagens pode não ser suficiente para distinguir com precisão as diferentes classes ou condições como pode ser observado na imagem 13 a seguir.

**Figura 13-Imagens semelhantes que causam confusão ao algoritmo levando a menor precisão na detecção de sintomas.**

(a) Sintoma de Ramulária (b) Sintoma causado por Mosca Minadora.



A sensibilidade (recall) que avalia a taxa de verdadeiros positivos é uma medida que quantifica a recepção de imagens corretamente identificadas como pertencentes a uma determinada classe (RODRIGUES, 2019). Neste trabalho, esse índice foi de 88%. Por outro lado, a especificidade quantifica as imagens corretamente identificadas como corretamente negativas, neste caso o índice foi de 85%.

A precisão mede a proporção de exemplos corretamente classificados como positivos (verdadeiros positivos) em relação ao total de exemplos classificados como positivos (verdadeiros positivos + falsos positivos), para este índice o desempenho foi de 86%. O índice F-score mede de forma harmônica o sistema ao considerar a relação entre os casos previstos como positivos que eram realmente positivos medidos pela precisão e os casos positivos identificados corretamente medidos pela sensibilidade (recall) obtidos o índice de 88%. Neste trabalho, em todos os classificados de desempenho o algoritmo teve avaliação acima de 80% o que indica uma maior assertividade do algoritmo em reconhecer as lesões foliares e extrair padrões, formas e cores que as distinguem (tabela 9).

**Tabela 9- Desempenho do modelo para as classes.**

Desempenho	
Acurácia	86,4
Sensibilidade (Recall)	88%
Especificidade	85%
Precisão	86%
F-Score	88%

Em um estudo semelhante, Silva et al. (2022) realizou uma pesquisa sobre detecção de patologias em folhas de tomateiros utilizando dois classificados baseados em redes neurais convolucionais: um desenvolvido pelos próprios autores e o Teachable Machine, uma

ferramenta desenvolvida pelo Google. Os resultados obtidos nesse trabalho demonstraram um desempenho superior em comparação ao presente trabalho. Neste trabalho os autores observaram que os classificadores apresentaram resultados melhores que a presente pesquisa alcançando acurácia de 97%.

Kaufan e Vilas Boas (2019), demonstram que as CNNs obtiveram resultados satisfatórios, mesmo quando treinadas com um banco de dados contendo apenas 50 imagens de doenças, sendo elas míldio da roseira, mancha negra da roseira, míldio pulverulento e cancro cítrico, alcançando acurácia de 70%. Com relação ao presente, é importante ressaltar que os resultados obtidos foram particularmente superiores em comparação ao estudo anterior de Kaufan e Vilas Boas (2019). Observe um ganho de precisão de até 14,6% e uma melhora significativa na acurácia, como pode ser visto nos resultados apresentados. Tabela 7.

Embora o desempenho das CNNs com arquitetura ResNet50 tenha sido positivo, pode ser melhorado, tendo em vista que trabalhos com banco de dados mais robusto contendo mais imagens geralmente alcançam maior acurácia. Outra possível causa para acurácia inferior a 90% é a ausência de um padrão de distância, horário e iluminação para a aquisição das imagens.

## **6. CONSIDERAÇÕES FINAIS**

Os resultados permitiram concluir que o algoritmo de Redes Neurais Convolucionais com arquitetura Resnet 50 é capaz de detectar lesões em folhas do algodoeiro como também identificar imagens com folhas sadias e fundo de forma precisa com acurácia superior a 80%. O estudo revelou que as CNNs podem alcançar altas taxas de precisão sem depender de uma grande quantidade de imagem, sendo, portanto, uma eficiente ferramenta para agricultura de precisão, bem como eficiente estratégia para uso racional dos produtos fitossanitários.

## **7. SUGESTÕES DE TRABALHOS FUTUROS**

Desenvolvimento de um dispositivo de alta resolução para Veículos Aéreos Não Tripulados (VANT's) com o objetivo de capturar imagens de excelente qualidade. Além disso, busca-se realizar a captura das fotos em horários programados para obter uniformidade na iluminação das fotografias.

## REFERÊNCIAS

ABRAPA Algodão no Mundo. **Associação Brasileira dos Produtores de Algodão**, [S.l.: s.n.]. 2022. Disponível em: <https://www.abrapa.com.br/Paginas/dados/algodao-no-mundo.aspx>  
Acesso em: 12 de nov 2022.

ALVES, G. **Entendendo Redes Convolucionais (CNNs)**. 1. ed. Medium, 2018. Disponível em: <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>.  
Acesso em: 1 jul. 2023.

ANSELMO, J. L et al. ESTIMATIVA DO CUSTO DE PRODUÇÃO DA CULTURA DO ALGODÃO EM CAROÇO, NA REGIÃO DOS CHAPADÕES–SAFRA 2010/11. 2012.

ANTONINI, R. C.; et al. ADOÇÃO E USO DA AGRICULTURA DE PRECISÃO NA REGIÃO DAS MISSÕES DO RIO GRANDE DO SUL. **HOLOS**, [S. l.], v. 4, p. 106–121, 2018. DOI: 10.15628/holos.2018.6297. Disponível em: <https://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/6297>. Acesso em: 24 jun. 2023.

ARAÚJO, A. D; MENTEN, J. O., Manchas foliares: ameaça permanente à cultura do algodão. **Revista Cultivar**, Pelotas, 2022. Disponível em: <https://revistacultivar.com.br/artigos/manchas-foliares-ameaca-permanente-a-cultura-do-algodao>. Acesso em 12 de nov 2022.

ARAÚJO, F. HD et al. Redes Neurais Convolucionais com Tensorflow: Teoria e Prática. SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos, v. 1, p. 382-406, 2017.

ARTUZO, F.D.; SOARES.C. WEISS, C. R.. Inovação de processo: O impacto ambiental e econômico da adoção da agricultura de precisão. **Espacios**, [S. l.], v. 38, n. 2, p. 1-6, 2018.

BALLESTEROS, R. D.; LORDSLEEM JUNIOR, A. C. Veículos Aéreos Não Tripulados (VANT) para inspeção de manifestações patológicas em fachadas com revestimento cerâmico. **Ambiente Construído**, [S. l.], v. 21, p. 119-137, 2020.

BARBEDO, J.G.A. GUARIENTI, E. M. TIBOLA, C. S. Detection of sprout damage in wheat kernels using NIR hyperspectral imaging. **Biosystems Engineering**, v.175, p.124-132, 2018.



BASSOI, L. H. et al. Agricultura de precisão e agricultura digital. **TECCOGS: Revista Digital de Tecnologias Cognitivas**, [S. l.], n. 20, p. 17-36, 2019.

BERGER, P. G. LIMA T.C. OLIVEIRA. R. Algodão no Cerrado: Logística e operações práticas: Vol: 1 O planejamento agrícola à aplicação de reguladores de crescimento. **CEAD**.1. ed. Viçosa - MG: UFV, v. 2. 2019.

CEPEA. PIB do Agronegócio Brasileiro-Centro de Estudos Avançados em Economia Aplicada-**CEPEA-Esalq**. USP.[S.l.; sd]. 2022.

CHIACCHIO, S. S. R; TEIXEIRA, B E; TECH, A. R. B. Vant: Um Estudo Sobre a Utilização de Veículo Aéreo Não Tripulado na Agricultura de Precisão. **Revista Científica Multidisciplinar Núcleo do Conhecimento**. [S. l.], Ed. 01, Vol. 12, Pp. 79-89, dezembro de 2016. ISSN: 2448- 0959.

COELHO, M. A. et al. Agricultura de precisão mapeia colheita de grãos. **Campo & Negócios**, Uberlândia, v. 10, n. 120, p. 36-40, fev. 2013.

CONAB. Safra 2022/23: Produção de grãos pode chegar a 308 milhões de t impulsionada pela boa rentabilidade de milho, soja e algodão. **Companhia Nacional de Abastecimento**[S.l.:s.n.]. 2023 Disponível em:<https://www.conab.gov.br/ultimas-noticias/4731-safra-2022-23-producao-de-graos-pode-chegar-a-308-milhoes-de-toneladas-impulsionada-pela-boarentabilidade-de-milho-soja-e-algodao#:~:text=As%20primeiras%20previs%C3%B5es%20para%20a.a%20comercializa%C3%A7%C3%A3o%20antecipada%2C%20entre%20outros>. Acesso em: 12 jun 2023.

COPPIN, Ben. Inteligência Artificial. Rio de Janeiro: LTC, 2013.

CORREIO BRAZILIENSE. Agro brasileiro bate recorde e exporta US\$ 14,25 bilhões. **Correio Brasiliense Economia**. [S.l.:s.n.]. Disponível em:<https://www.correiobrasiliense.com.br/economia/2022/11/5051388-agro-brasileiro-bate-recorde-e-exporta-uss-1425-bilhoes.html> . Acesso em 05 nov 2022.

COSTA, D. C. *et al.* USO DE IMAGENS DIGITAIS PARA AVALIAÇÃO DO CRESCIMENTO DE *Monilinia fructicola* EM NECTARINA ‘AUROJIMA’. In:

- CONGRESSO PAULISTA DE FITOPATOLOGIA, XL., 2017, Campinas. Anais [...] **Botucatu: Summa Phytopathologica**, 2017. P. 1-6.
- COTA, L.V. *et al.* Manejo da cigarrinha e enfezamentos na cultura do milho. Sete Lagoas: **Embrapa Milho e Sorgo**, 2021. 16 p. Cartilha.
- CROSS, S. S.; HARRISON, R. F.; KENNEDY, R. L. Introduction to neural networks. *The Lancet*, v. 346, n. 8982, p. 1075-1079, 1995.
- DA SILVA, W. V. R; SILVA-MANN, R. Agricultura de Precisão no Brasil: conjuntura atual, desafios e perspectivas. **Research, Society and Development**, v. 9, n. 11, p. e1979119603-e1979119603, 2020.
- DE ALMEIDA, R. P.; SOARES, J. J.; DE ALBUQUERQUE, F. A Manejo agroecológico de pragas do algodoeiro. **Embrapa Algodão-Circular Técnica (INFOTECA-E)**, 2019.
- DE SOUSA. R. DE BRITO, R. Sistema de Classificação do Capsicum Annuum Acometido Pela Doença Fúngica Antracnose Através do Random Forest. *In: ESCOLA REGIONAL DE COMPUTAÇÃO DO CEARÁ, MARANHÃO E PIAUÍ (ERCEMAPI)*, 8. , 2020, Evento Online. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2020 . p. 23-29.
- EMBRAPA, ALGODÃO. **Controle químico da mancha de ramulária do algodoeiro**. [S. l.], 2018. Disponível em: <https://www.embrapa.br/en/busca-de-projetos/-/projeto/210930/control-quimico-da-mancha-de-ramularia-do-algodoeiro>. Acesso em: 25 jul. 2023.
- EMRICH, E.B.; LUPPI, M. J.R.; SALDANHA, C. B.. Fitotecnia: Algodão e Mandioca. LONDRINA: **Editora e Distribuidora Educacional S.A**, 2018. 192 p. v. 1. ISBN 978-85-522-0752-8.
- FERRARI, D. G.; DE CASTRO SILVA, L. N. **Introdução a mineração de dados**. [s.l.] Saraiva Educação S.A., 2017.
- FERREIRA, Bianca Nicoletti et al. Cadeia produtiva do algodão no Brasil. **Research, Society and Development**, v. 11, n. 10, p. e298111031730-e298111031730, 2022.
- FLECK L. et al. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

GONZALEZ, R. C. WOODS, R. E. Processamento digital de imagens. 3. ed. São Paulo: Pearson, 2010.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. [S.l.]: **MIT Press**, 2016.

GRINBLAT, Guillermo L. et al. Deep learning for plant identification using vein morphological patterns. **Computers and electronics in agriculture**, v. 127, p. 418-424, 2016.

HE, Q. et al. Cotton Pests and Diseases Detection based on Image Processing. **TELKOMNIKA**, v. 11, n. 6, p. 3445-3450, 2016.

HOLANDA, S.M. E. et al. Aplicação de aprendizado de máquina profundo para detecção por imagens de doenças em frutos do cacaueteiro. **International Journal of Development Research**, v. 11, n. 05, p. 47378-47384, 2021.

IKEDA, M. Sem o manejo correto, pragas sugadoras causam prejuízos em lavouras de algodão. **AgroANALYSIS**, v. 39, n. 10, p. 25-25, 2019.

INAMASU, R. Y.; BERNARDI, A. C. C. Agricultura de precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 21-33.

JORGE, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 109-134.

KAUFMAN, D. BOAS, L. L. V. Visão computacional na agricultura: APIs de detecção e reconhecimento de doenças das plantas. **TECCOGS: Revista Digital de Tecnologias Cognitivas**, n. 20, 2019.

LAMAS, F. M. O mercado global do algodão - efeitos da pandemia decorrente do novo coronavírus. **Embrapa Agropecuária Oeste**, [S.l.] 2020. Disponível em: <https://www.embrapa.br/en/busca-de-noticias/-/noticia/51799538/artigo---o-mercado-global-do-algodao---efeitos-da-pandemia-decorrente-do-novo-coronavirus> Acesso em 29 nov/22.

Acesso jun 2023

LANDIS, R.J. e KOCH The measurement of observer agreement for categorical data. **Biometrics**, [S.l.] v. 33, p. 159-174, 1977.

LECUN, Y.; BENGIO, Y.; HINTON, G. Aprendizagem profunda. [S.l.] **Natureza**, v. 521, n. 7553, pág. 436-444, 2015.

LOCATELLI, Tamara et al. Redes neurais artificiais para estimativa da fitotoxidez de Saflufenacil em mudas de Café Conilon. **Revista em Agronegócio e Meio Ambiente**, v. 14, n. 4, p. 1-13, 2021.

LOPES, L. O. et al. Efeito de fungicidas para o controle da *Ramularia areola* na cultura do algodoeiro. **Summa Phytopathologica**, [S.l.] v. 43, n. 3, p. 229-235, 2017.

MARGIOTTI, A. F. C.; SILVA, R. I. A. Cálculo automático de área foliar da soja danificada. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, [S.l.], v. 34, n. esp., p. 11-20, jul. 2018. ISSN 2596-2809. Disponível em: <http://periodicos.unifil.br/index.php/Revistatest/article/view/292>. Acesso em: 24 jun. 2023.

McCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v.5, p.115-133, 1943.

MEDEIROS, F. A. *et al.* Utilização de um veículo aéreo não-tripulado em atividades de imageamento georeferenciado. **Ciência Rural**, [S.l.], v. 38, p. 2375-2378, 2008.

MINISTÉRIO DA ECONOMIA. Secretaria de Comércio Exterior. **Sistema ComexStat Exportação e Importação Geral**. Brasília: ME: SECEX, 2022. Disponível em: <http://comexstat.mdic.gov.br/pt/geral/62729>. Acesso em: 11/05/2023.

MIRANDA, A. C. C; VERÍSSIMO, A. M.; CEOLIN, A C. Agricultura de precisão: um mapeamento da base da Scielo. **GESTÃO. Org**, [S.l.], v. 15, n.6, p. 129-137, 2017.

MIRANDA, E. J. Manejo integrado de pragas do algodoeiro no cerrado brasileiros. **Circular técnica**, Paraíba, n. 131, 37 p, 2010.

MOLIN, J. P. Agricultura de precisão: números do mercado brasileiro. **Boletim Técnico, USP ESALQ**, Piracicaba, v. 3, p. 7, 2017.

MOREIRA, L. *et al.* A Utilização da Lógica Fuzzy Como Ferramenta Auxiliar na Detecção de Doenças Fúngicas do Tomateiro Como a Septoriose. In: **ESCOLA REGIONAL DE COMPUTAÇÃO DO CEARÁ, MARANHÃO E PIAUÍ (ERCEMAPI)**, 8. , 2020, Evento Online. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2020 . p. 9-15.

MUKHERJEE, S. The Annotated ResNet-50 - Towards Data Science. **Medium.** , [S.l.: s.n.]. 2022. Disponível em: <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758>. Acesso em: 6 jun. 2023.

NETO, J. C. *et al.* Uso de redes neurais convolucionais para detecção de laranjas no campo. In: **SBIAgro Congresso Brasileiro de Agroinformática**, Indaiatuba (SP) -2019 **Anais [...]**. Indaiatuba (SP): INF 2019.

NUNES, C. D; LOPES, L. F. B. Proposta Metodológica para Avaliação de Produtividade de Lavouras de soja Baseada em Visão Computacional e Aprendizagem de Máquina. **DIVERSITÀ: Revista Multidisciplinar do Centro Universitário Cidade Verde**, [S.l.].v. 2, n. 2, 2016.

ONU. Dia Mundial do Algodão 2022 celebra papel da cotonicultura no desenvolvimento sustentável, Organização das Nações Unidas. **ONU News Perspectiva Global Reportagens Humanas**, [S.l.:s.n.]. 2022. Disponível em: <https://news.un.org/pt/story/2022/10/1803357#:~:text=Estima%2Dse%20que%20cerca%20de,tecidas%2C%20como%20filtros%20e%20preenchimentos>. Acesso em 29 nov 22.

ONU. População mundial atinge 8 bilhões de pessoas. Organização das Nações Unidas. **ONU News**. [S.l.:s.n.]. 2022. Disponível em: <https://news.un.org/pt/story/2022/11/1805342>. Acesso em: 12 mai 2023.

PACIFICO, L. D. S. Segmentação Automática de Doenças em Imagens de Plantas através de Algoritmos Evolucionários. In: **BRAZILIAN E-SCIENCE WORKSHOP (BRESKI)**, 14. , 2020, Cuiabá. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2020. p. 25-32. ISSN 2763-8774 PEREIRA, L.S. *et al.* Sensoriamento remoto aplicado à agricultura de precisão no cultivo de bambu. **Revista Mackenzie de Engenharia e Computação**, São Paulo, v. 16, n. 1, p. 8-33, 2020.

PEREIRA , N, C; CASTRO, N, C. EXPANSÃO DA PRODUÇÃO AGRÍCOLA, NOVAS TECNOLOGIAS DE PRODUÇÃO, AUMENTO DE PRODUTIVIDADE E O DESNÍVEL

TECNOLÓGICO NO MEIO RURAL. **IPEA Instituto de Pesquisa Econômica Aplicada**, Rio de Janeiro, ano 2022, v. 1, n. 1, p. 1-74, 2 maio 2022.

PONTI, M. et al. Precision Agriculture: Using Low-Cost Systems to Acquire Low-Altitude Images. *IEEE Computer Graphics and Applications*, IEEE, v. 36, n. 4, p. 14–20, 2016.

RAUBER, Thomas Walter. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.

RILEY, D. G. Economic injury level (EIL) and economic threshold (ET) concepts in pest management. In: CAPINERA, J. E. (ed.). **Encyclopedia of Entomology**. **Dordrecht: Springer**, 2008. p. 1282-1286.

RODRIGUES, S, S; DE BARROS, M. M. O Uso de VANT e do Sensoriamento Remoto como Ferramenta de Melhoria das Técnicas de Agricultura de Precisão. **Corpo Editorial**, p. 61, 2018.

RODRIGUES, V. **Conhecendo a visão do computador: Redes Neurais Convolucionais**. Medium. [S.l.;s.n]. 2019. Disponível em: <https://vitorborbarodrigues.medium.com/conhecendo-a-vis%C3%A3o-do-computador-redes-neurais-convolucionais-e1c2b14bf426>. Acesso em: 4 jun. 2023.

ROSENBLATT, Frank. O perceptron: um modelo probabilístico para armazenamento e organização de informações no cérebro. **Revisão psicológica** , v. 65, n. 6, pág. 386, 1958.

RUSSAKOVSKY, O *et al.* ImageNet Large Scale Visual Recognition Challenge. **Cornell University**, [S. l.], ano 2015, v. 3, n. 3, p. 1-43.

SAMPAIO, H. S *et al.* Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado. (VANT) E SATÉLITE, **Revista Brasileira de Engenharia de Biosistemas**, [S.l.]. vol 14, no 2, bl 111–124, Jun 2020.

SANTANA, C. A. M. Cerrado: pilar da agricultura brasileira. In: In: BOLFE, E. L. *et al.* (Ed.). Dinâmica agrícola no cerrado: análises e projeções. Brasília, DF: **Embrapa**, 2020. v. 1, cap. 2, p. 39-58.

SANTOS FILHO, H. P. *et al.* Manejo integrado de pragas e doenças do mamoeiro com base em resultados de monitoramento. 2009. In: SIMPÓSIO SOBRE MANEJO DE PRAGAS, 1.,

2009, Belém, PA. Manejo integrado de pragas, doenças e plantas daninhas em grãos e fruteiras: anais. Belém, PA: **Embrapa Amazônia Oriental**, 2009.

SANTOS, E. Pesquisadores orientam sobre o controle da mancha de ramulária. 1. ed. Embrapa Algodão, 3 nov. 2015. Disponível em: <https://www.embrapa.br/en/busca-de-noticias/-/noticia/2551143/pesquisadores-orientam-sobre-controle-da-mancha-de-ramularia>. Acesso em: 25 jul. 2023.

SEAPA. Minas Gerais deve produzir 113,1 mil toneladas de algodão na safra 2021/2022. **Secretaria de Estado de Agricultura, Pecuária e Abastecimento de Minas Gerais**. [S.l.;s.n.], 2022. Disponível em: <http://www.agricultura.mg.gov.br/index.php/ajuda/story/5011-minas-gerais-deve-produzir-113-1-mil-toneladas-de-algodao-na-safra-2021-2022>. Acesso em: 12 nov 2022.

SILVA, C. F. B. *et al.* Uso do Trichoderma na cultura da banana. In: MEYER, M. C. *et al.* **Trichoderma: uso na agricultura**. Brasília: Embrapa, 2019. p. 433-444.

SILVA, L. *et al.* Detecção de Patologias em Folhas de Tomateiros Utilizando Dois Classificadores. **XL SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS - SBt**, RITA DO SAPUCAÍ, v. 1 , p. 1-5. 2022

SILVA, W. DE VR DA; SILVA-MANN, R. Agricultura de Precisão no Brasil: conjuntura atual, desafios e perspectivas. **Research, Society and Development**, [S.l.], 2020, v. 9, n. 11, p. e1979119603.

SLONGO, A. G. *et al.* DEFINIÇÃO DE REQUISITOS DE PROJETO PARA UM VEÍCULO AÉREO NÃO TRIPULADO (VANT) PARA PULVERIZAÇÃO AGRÍCOLA.. In: Anais do 2º Congresso Aeroespacial Brasileiro. **Anais...** Santa Maria(RS) Universidade Federal de Santa Maria, 2017.

SOELA, D. M. *et al.* Controle estatístico de processo em pulverização usando veículo aéreo não tripulado na cultura do café conilon. **Brazilian Journal of Production Engineering**, [S. l.], v. 6, n. 4, p. 52–63, 2020.SOUSA, L. B. O Algodoeiro: alguns aspectos importantes da cultura. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 5, n. 4, p. 3, 2010.

SOUZA, L, S CAPACIDADE GERAL E ESPECÍFICA DE COMBINAÇÃO EM ALGODOEIRO HERBÁCEO PARA QUALIDADE DE FIBRA. 2017.

SOUZA, V. et al. Análise comparativa de redes neurais convolucionais no reconhecimento de cenas. **Anais do Computador na Praia**, [S.l.], v. 11, n. 1, pág. 419-426, 2020.

SPERANZA, E. A., CIFERRI, R. R. Integração de ferramentas de SIG e mineração de dados para utilização em atividades de gestão espacialmente diferenciada aplicada na agricultura de precisão. Embrapa Informática Agropecuária. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA **Editora da Unicamp: Embrapa Informática Agropecuária**, 11., 2017, Campinas. Ciência de dados na era da agricultura digital: anais. Campinas:, 2017.

SUASSUNA, N.D. e MORELLO, C. L. História do melhoramento do algodoeiro na Embrapa para o Cerrado do Brasil. **Embrapa Algodão 2ª edição**, [S.l.], 2017. Disponível em: [https://www.spo.cnptia.embrapa.br/conteudo?p\\_p\\_id=conteudoportlet\\_WAR\\_sistemasdeproducao16\\_1galceportlet&p\\_p\\_lifecycle=0&p\\_p\\_state=normal&p\\_p\\_mode=view&p\\_p\\_col\\_id=column-1&p\\_p\\_col\\_count=1&p\\_r\\_p\\_-76293187\\_sistemaProducaoId=7718&p\\_r\\_p\\_-996514994\\_topicoId=1307](https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistemasdeproducao16_1galceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoId=7718&p_r_p_-996514994_topicoId=1307) Acesso em 27 nov 2022.

TAFNER, M. A. Redes Neurais Artificiais: Aprendizado e Plasticidade. 1. ed. Campinas, 25 maio 1998. Disponível em: <https://cerebromente.org.br/n05/tecnologia/rna.htm>. Acesso em: 12 jul. 2023.

TEIXEIRA, H. et al. Controle alternativo de pragas e doenças: opção ou necessidade? Ferramentas do manejo alternativo de doenças de plantas. In: CONTROLE alternativo de pragas e doenças: opção ou necessidade?: Ferramentas do manejo alternativo de doenças de plantas. 1. ed. Belo Horizonte: **EPAMIG**, 2021. v. 1, cap. 14, p. 125-134. ISBN 978-65-86500-08-0.

TELES, G. C.; FUCK, M. P. Pesquisa e desenvolvimento de cultivares: o perfil tecnológico da cotonicultura brasileira. **Informe GEPEC**, [S. l.], v. 20, n. 1, p. 61–77, 2016. DOI: 10.48075/igepec.v20i1.13377. Disponível em: <https://e-revista.unioeste.br/index.php/gepec/article/view/13377>. Acesso em: 22 mai 2023.

TELES, Giuliana Cardoso; PORRA, Marcos Paulo. Pesquisa e desenvolvimento de cultivares: o perfil tecnológico da cotonicultura brasileira. **Informe Gepec**, v. 20, n. 1, pág. 61-77, 2016.

USDA. Cotton: World Markets and Trade. **United States Department Agriculture**. [S.l.], 2022. Disponível em: <https://apps.fas.usda.gov/psdonline/circulars/cotton.pdf>. Acesso em: 19 jun 2022.



VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: **Proceedings of the XXIX Conference on Graphics, Patterns and Images**. [S.l.] 2016. p. 1-4.

VERMA, K; SINGH, P. An Insight to Soft Computing based Defect Prediction Techniques in Software. **I.J. Modern Education and Computer Science**, [S. l.], ano 2015, v. 1, n. 1, p. 52-58, 7 set. 2015. DOI 10.5815/ijmecs.2015.09.07. Disponível em: <https://www.mecspress.org/ijmecs/ijmecs-v7-n9/IJMECS-V7-N9-7.pdf>. Acesso em: 10 jul. 2023.

WU, J. Introduction to Convolutional Neural Networks. **National Laboratory of Keys to New Software Technologies. Nanjing University. China**, v. 5, n. 23, pág. 495, 2017.

ZHANG, J. *et al.* Assessing crop damage from dicamba on non-dicamba-tolerant soybean by hyperspectral imaging through machine learning. **Pest Management Science**. [S.l.], v. 75, p. 3260–3272, 2019.