

**INSTITUTO FEDERAL**

Goiano

*Campus Rio Verde*

**BACHARELADO EM AGRONOMIA**

**TRANSFORMANDO A AGRICULTURA:  
PRINCÍPIOS FUNDAMENTAIS E DESAFIOS  
DA INTELIGÊNCIA ARTIFICIAL**

**Autielis Aparecido Rodrigues Ferreira**

**Rio Verde, GO**

**2024**

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA  
GOIANO – CAMPUS RIO VERDE  
BACHARELADO EM AGRONOMIA**

**TRANSFORMANDO A AGRICULTURA: PRINCÍPIOS  
FUNDAMENTAIS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL**

**Autielis Aparecido Rodrigues Ferreira**

Trabalho apresentado ao Instituto Federal Goiano – Campus Rio Verde, como requisito parcial para a obtenção do Grau de Bacharel em Agronomia.

Orientador: Tavvs Micael Alves

**Rio Verde, GO**

**abril, 2024**

Sistema desenvolvido pelo ICMC/USP  
Dados Internacionais de Catalogação na Publicação (CIP)  
**Sistema Integrado de Bibliotecas - Instituto Federal Goiano**

FF383t Ferreira, Autielis Aparecido Rodrigues  
TRANSFORMANDO A AGRICULTURA: PRINCÍPIOS  
FUNDAMENTAIS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL /  
Autielis Aparecido Rodrigues Ferreira; orientador  
Tavvs Micael Alves; co-orientador Marconi Batista  
Teixeira. -- Rio Verde, 2024.  
31 p.

TCC (Graduação em Bacharelado em Agronomia) --  
Instituto Federal Goiano, Campus Rio Verde, 2024.

1. redes neurais. 2. aprendizado de máquina. 3.  
visão computacional. 4. deep learning. I. Alves,  
Tavvs Micael, orient. II. Teixeira, Marconi Batista,  
co-orient. III. Título.

# TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

## IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- |  |   |
|--|---|
| <input type="checkbox"/> Tese (doutorado)            | <input type="checkbox"/> Artigo científico              |
| <input type="checkbox"/> Dissertação (mestrado)      | <input type="checkbox"/> Capítulo de livro              |
| <input type="checkbox"/> Monografia (especialização) | <input type="checkbox"/> Livro                          |
| <input checked="" type="checkbox"/> TCC (graduação)  | <input type="checkbox"/> Trabalho apresentado em evento |

Produto técnico e educacional - Tipo:

Nome completo do autor:

**AUTIELIS APARECIDO RODRIGUES FERREIRA**

Matrícula:

**2016102200240388**

Título do trabalho:

**TRANSFORMANDO A AGRICULTURA: PRINCÍPIOS FUNDAMENTAIS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL**

## RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial:  Não  Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: **26 /07 / 2024**

O documento está sujeito a registro de patente?  Sim  Não

O documento pode vir a ser publicado como livro?  Sim  Não

## DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Rio Verde, GO

27 /07 / 2024

Local

Data

Documento assinado digitalmente



**AUTIELIS APARECIDO RODRIGUES FERREIRA**

Data: 10/10/2024 22:54:28-0300

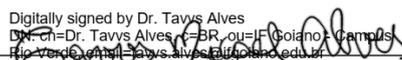
Verifique em <https://validar.iti.gov.br>

Assinat

autorais

Ciente e de acordo:

Digitally signed by Dr. Tavys Alves

  
DN: cn=Dr. Tavys Alves, c=BR, ou=IF Goiano - Campus  
Rio Verde, o=Autielis Rodrigues Ferreira, email=

Date: 2024.08.01 09:23:08 -03'00'

Assinatura do(a) orientador(a)



SERVIÇO PÚBLICO FEDERAL  
MINISTÉRIO DA EDUCAÇÃO  
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA  
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Ata nº 47/2024 - DPGPI-RV/CMPRV/IFGOIANO

### **ATA DE DEFESA DE TRABALHO DE CURSO**

Ao(s) 03 dia(s) do mês de abril de 2024, às 16 horas e 00 minutos, reuniu-se a banca examinadora composta pelos docentes: TAVVS MICAEL ALVES (orientador), Marconi Batista Teixeira (membro), Rômulo Moreira Silva (membro), para examinar o Trabalho de Curso intitulado “TRANSFORMANDO A AGRICULTURA: PRINCÍPIOS FUNDAMENTAIS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL” do(a) estudante Autielis Aparecido Rodrigues Ferreira, Matrícula nº 2016102200240388 do Curso de Agronomia do IF Goiano – Campus Rio Verde. A palavra foi concedida ao(a) estudante para a apresentação oral do TC, houve arguição do(a) candidato pelos membros da banca examinadora. Após tal etapa, a banca examinadora decidiu pela APROVAÇÃO do(a) estudante. Ao final da sessão pública de defesa foi lavrada a presente ata que segue assinada pelos membros da Banca Examinadora.

*(Assinado Eletronicamente)*

TAVVS MICAEL ALVES

Orientador(a)

*(Assinado Eletronicamente)*

Marconi Batista Teixeira

Membro

*(Assinado Eletronicamente pelo orientador.*

*Conforme autorizado pelo membro)*

Rômulo Moreira Silva

Membro

**Observação:**

( ) O(a) estudante não compareceu à defesa do TC.

Documento assinado eletronicamente por:

- Marconi Batista Teixeira, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 17/05/2024 17:41:38.
- Tavvs Micael Alves, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 17/05/2024 15:26:18.

Este documento foi emitido pelo SUAP em 03/05/2024. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 598059

Código de Autenticação: 02ade33169



INSTITUTO FEDERAL GOIANO

Campus Rio Verde

Rodovia Sul Goiana, Km 01, Zona Rural, 01, Zona Rural, RIO VERDE / GO, CEP 75901-970

(64) 3624-1000

*Com todo carinho, dedico este trabalho à **DEUS** e minha amada família, especialmente aos meus queridos pais, Franciso e Rosimeire, à minha irmã, Aline Regina, e aos meus amados avós, Zé Marinheiro e Dona Maria, ambos em memória, assim como ao meu avô materno, Sabino, também em memória. Eles sempre acreditaram em mim, mesmo nos momentos em que eu duvidava de mim mesmo durante esta jornada. São verdadeiramente meus maiores exemplos de vida. Este trabalho é dedicado a eles com imenso amor.*

*“Quem sabe, divide. Quem não sabe, pergunta”. (Mario Sergio Cortella)*

## AGRADECIMENTO

Agradeço a todos que, de forma direta ou indireta, contribuíram para a realização deste trabalho. Em especial, expresso minha gratidão ao meu orientador e amigo, Tavvs Micael Alves, pela sua infinita paciência e apoio, mesmo diante das várias mudanças de tema deste trabalho. Sua constante confiança em mim foi fundamental.

Quero também reconhecer o incrível apoio do estimado professor Marconi Batista Texeira, a quem guardo um carinho imenso. Desde os tempos em que eu era membro do centro acadêmico do curso até o presente momento, ele sempre esteve disponível para me auxiliar.

À comunidade do grupo SAPFLY, do qual faço parte, grupo que tem como objetivo discussões correlatas ao tema do meu trabalho.

Agradeço também ao Polo de Inovação do IF Goiano – *Campus* Rio Verde, qual fui bolsista, participar do projeto de inovação despertou ainda mais minha curiosidade pela temática abordada neste trabalho. Sua contribuição foi fundamental para o meu desenvolvimento acadêmico e pessoal.

Não posso deixar de mencionar os professores do curso de agronomia, que demonstraram dedicação incansável para garantir um ensino de qualidade, mesmo diante de desafios adversos.

Aos colaboradores e prestadores de serviços desta instituição de ensino, cujo trabalho é vital para o funcionamento dos cursos, desde os técnicos até a pós-graduação, expresso minha sincera gratidão.

Ao Grupo Associado de Pesquisa do Sudoeste Goiano – GAPES, do qual faço parte, agradeço pelo apoio na conclusão desta etapa da minha vida acadêmica.

Aos meus queridos amigos, que sempre estiveram ao meu lado, torcendo por mim e nunca desistindo de mim, não posso expressar minha gratidão suficientemente. Opto por não mencionar nomes, pois não quero ser injusto ao esquecer alguém; cada um de vocês teve um papel fundamental em minha jornada acadêmica.

Aos meus colegas de curso e profissão, agradeço por compartilharem essa jornada comigo.

## RESUMO

FERREIRA, Autielis Aparecido Rodrigues. **TRANSFORMANDO A AGRICULTURA: PRINCÍPIOS FUNDAMENTAIS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL** 2024.35p Monografia (Curso de Bacharelado em Agronomia). Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Rio Verde, Rio Verde, GO, 2024.

A agricultura moderna busca eficiência e sustentabilidade, impulsionando a integração de sistemas inteligentes de automação e gestão. Esses sistemas processam dados para monitorar lavouras, permitindo a aplicação precisa de insumos em taxas variáveis. Essa abordagem, alinhada a considerações ambientais, visa aumentar a produção de alimentos em resposta ao crescimento populacional global. A adoção generalizada desses sistemas inteligentes é antecipada, prometendo ser mais eficaz e sustentável que os métodos de gerenciamento agrícola convencionais. Este estudo concentra-se em estabelecer os princípios fundamentais da inteligência artificial (IA) na agricultura, visando oferecer suporte à avaliação de conceitos aplicados e preparar o terreno para análises mais especializadas sobre implementações bem-sucedidas de IA nesse setor. Trata-se de uma revisão analítica da aplicação da inteligência artificial nos sistemas de produção agrícola, resultante de uma revisão bibliográfica. Os dados foram coletados na base Science Direct, abrangendo artigos publicados entre 2019 e 2023 para fornecer informações recentes. Os critérios de inclusão envolveram artigos com descritores como "agriculture production systems" e "artificial intelligence". A adoção plena da inteligência artificial na agricultura enfrenta desafios fundamentais, como a necessidade de dados confiáveis, resistência dos agricultores a novas tecnologias, infraestrutura inadequada em certas regiões agrícolas e preocupações com a segurança dos dados. Superar esses desafios é essencial para desbloquear todo o potencial transformador da inteligência artificial na agricultura, facilitando uma produção mais sustentável e eficiente diante das crescentes demandas globais por alimentos.

Palavras-chave: redes neurais, aprendizado de máquina, visão computacional, deep learning.

## **LISTA DE FIGURAS**

|  |    |
|--|----|
| <a href="#"><u>Figura 1 - Modelo de Rede Neural Artificial - Perceptron de Múltiplas Camadas (MLP) (ICMC-USP, 2016).</u></a>   | 14 |
| <a href="#"><u>Figura 2 - Estrutura de uma Rede Neural Convolutacional voltada para tarefas de classificação.</u></a>  | 16 |
| <a href="#"><u>Figura 3 - Nuvem de palavras criada a partir dos resumos dos artigos selecionados, onde as palavras mais frequentes são exibidas em maior tamanho de fonte na imagem.</u></a>   | 23 |
| <a href="#"><u>Figura 4 - (A) Identificação de plantas-alvo. (B) Localização autônoma de plantas daninhas. Caixas vermelhas contêm plantas cultivadas que devem permanecer intocadas durante o processo de remoção de ervas daninhas. Caixas verdes, por outro lado, indicam a localização das ervas daninhas. (C) Um exemplo de remoção complexa de ervas daninhas (próximo à cultura principal).</u></a> | 25 |
| <a href="#"><u>Figura 5 - Uma seção do campo visualizado em (a) bandas RGB, (b) limites gerados pelo algoritmo SLIC, (c) dimensão de cada patch, (d) resultado da rotulagem e (e) dados de referência para a gravidade da doença.</u></a>  | 26 |

## **LISTA DE QUADROS**

|  |    |
|--|----|
| <a href="#"><u>Quadro 1 - Distribuição do resultado da busca por revista</u></a> | 17 |
|--|----|

## **LISTA DE TABELAS**

|  |    |
|--|----|
| <a href="#"><u>Tabela 1 - Artigos de pesquisa selecionados na <i>Science Direct</i>.</u></a> | 18 |
|--|----|

## LISTA DE ABREVIACOES E SMBOLOS

|              |  |
|--------------|--|
| ANN          | Redes neurais artificiais  |
| ARIMA        | Modelo estatstico amplamente utilizado na anlise de sries temporais para fazer previses.   |
| CIGREEN      | ndice de clorofila verde  |
| CIREN-EDGE   | ndice de clorofila red-edge   |
| CNN          | Rede Neural Convolutacional so um tipo especializado de arquitetura de rede neural projetada para processar dados bidimensionais, como imagens. |
| DENSENET     | Rede neural convolutacional densa  |
| FCN          | Redes totalmente convolutacionais  |
| FNN          | Redes neurais difusas  |
| GEP          | Programao de expresso gentica   |
| GNDVI        | ndice de vegetao de diferena normalizada verde  |
| GPS          | Sistema de navegao por satlite que permite determinar a localizao precisa de um receptor em qualquer lugar do mundo.                          |
| GPU          | Unidade de processamento grfico   |
| IA           | Inteligncia artificial  |
| IOT          | Internet das Coisas  |
| LORA         | Tecnologia de comunicao sem fio projetada para possibilitar a transmisso de dados em longas distncias com baixo consumo de energia            |
| MSV          | Vrus do mosaico do milho  |
| MZS          | Zonas de manejo  |
| NDVI         | ndice de vegetao de diferena normalizada  |
| NDVIRED-EDGE | ndice de vegetao de diferena normalizada  |
| OSAVI        | ndice de vegetao ajustado otimizado  |
| PIB          | Produto interno bruto  |
| RF           | Random Forest.   |

|       |   |
|-------|---|
| RGB   | RGB significa "Red, Green, Blue" e é um sistema de cores usado em dispositivos eletrônicos.   |
| RGB-D | Imageamento RGB e de profundidade (D)   |
| RNA   | Redes neurais artificiais   |
| RTK   | Refere-se a uma técnica de posicionamento global que utiliza informações de correção em tempo real para melhorar a precisão do GPS. |
| SAVI  | Índice de vegetação ajustado ao solo  |
| SR    | Razão simples   |
| UAV   | Veículo aéreo não tripulado   |

## SUMÁRIO

|              |  |    |
|--------------|--|----|
| <u>1</u>     | <u>INTRODUÇÃO</u> .....                                  | 10 |
| <u>2</u>     | <u>REVISÃO DE LITERATURA</u> .....                       | 11 |
| <u>2.1</u>   | <u>Fundamentos da inteligência artificial</u> .....      | 11 |
| <u>2.2</u>   | <u>Algoritmos e técnicas relevantes</u> .....            | 13 |
| <u>2.2.1</u> | <u>Redes Neurais Artificiais (RNAs)</u> .....            | 13 |
| <u>2.2.2</u> | <u>Árvores de Decisão</u> .....                          | 14 |
| <u>2.2.3</u> | <u>Aprendizado Profundo (<i>Deep Learning</i>)</u> ..... | 14 |
| <u>2.2.4</u> | <u>Redes Neurais Convolucionais</u> .....                | 15 |
| <u>3</u>     | <u>METODOLOGIA</u> .....                                 | 16 |
| <u>4</u>     | <u>RESULTADOS E DISCUSSÕES</u> .....                     | 17 |
| <u>5</u>     | <u>CONSIDERAÇÕES FINAIS</u> .....                        | 27 |
| <u>6</u>     | <u>BIBLIOGRAFIA</u> .....                                | 29 |

## 1 INTRODUÇÃO

A agricultura no Brasil é amplamente reconhecida por sua alta competitividade e seu papel fundamental na geração de empregos, riqueza, produção de alimentos, fibras e bioenergia, tanto para o país quanto para outras nações. Este setor desempenha um papel vital no crescimento do Produto Interno Bruto (PIB) nacional, representando 21% da soma de todas as riquezas produzidas, além de ser responsável por um quinto de todos os postos de trabalho e por impressionantes 43,2% das exportações brasileiras, totalizando US\$ 96,8 bilhões em 2019 (MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, 2022). Em um cenário em que poucos segmentos da economia brasileira conseguiram crescer, a agricultura se destacou com um crescimento positivo. Além disso, internamente, esse setor desempenhou um papel importante na contenção do aumento dos preços reais dos alimentos essenciais na cesta básica.

A agricultura está se tornando cada vez mais dependente da inteligência artificial para lidar com seus desafios. Isso acontece porque há muitos fatores complicados envolvidos na produção agrícola, como o uso eficiente de energia e água, a preservação da natureza e a redução de gases de efeito estufa. Além disso, os agricultores precisam acompanhar as demandas dos consumidores e as mudanças nos mercados. Tudo isso é influenciado por questões econômicas, políticas, sociais e culturais. A inteligência artificial ajuda os agricultores a lidarem com esses desafios de forma mais eficaz e sustentável. (LOPES, 2023).

As mais recentes estimativas das Nações Unidas indicam que a população global poderá atingir aproximadamente 9,7 bilhões de pessoas até 2050, com previsões de um pico em torno de 10,4 bilhões durante a década de 2080, mantendo-se nesse patamar até o ano 2100 (UNITED NATIONS, 2022). Isso implica na necessidade substancial de aumentar a produção de alimentos em comparação com os níveis atuais.

As atuais demandas por eficiência econômica e sustentabilidade na agricultura moderna destacam a necessidade de incorporar sistemas inteligentes de automação e gestão, capazes de processar dados coletados em campo para monitorar as lavouras de forma precisa. Esse monitoramento possibilita a aplicação de insumos em taxas variáveis, orientando a administração de sistemas agrícolas de maneira alinhada com as considerações ambientais. Além disso, abre caminho para aumentar a produção de alimentos em resposta ao crescimento populacional global. Prevê-se que a adoção generalizada desses sistemas inteligentes se torne mais difundida, eficaz e sustentável em comparação com os sistemas de gerenciamento de lavouras atualmente em uso (TETILA, 2019).

A evolução da influência da inteligência artificial (IA) nos negócios e na cadeia de valor agrícola percorreu várias etapas desde que o termo foi introduzido no Workshop de Dartmouth em 1955. Essa trajetória incluiu períodos de escassez de financiamento para pesquisas, com expectativas modestas de retornos econômicos, até chegar à atual fase de grande otimismo. A fase otimista atual é respaldada por diversos fatores que possibilitam a implementação prática em larga escala desse conceito, como assistentes de voz virtuais e aplicativos de reconhecimento de imagem integrados a dispositivos móveis (MEGETO, SILVA, *et al.*, 2020).

Stuart Russell, um renomado cientista da computação e autor de "Artificial Intelligence: A Modern Approach," define a inteligência artificial como o estudo de agentes inteligentes, ou seja, sistemas que podem perceber seu ambiente, raciocinar sobre as informações recebidas, tomar decisões para alcançar objetivos específicos e agir com base nessas decisões. Esses agentes podem ser tanto máquinas físicas quanto programas de computador, e a IA busca desenvolver sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, como aprendizado, resolução de problemas, compreensão de linguagem natural e reconhecimento de padrões (RUSSELL, 2010).

A escolha deste tema se baseia na vital importância da agricultura para a sobrevivência humana, sua influência crítica na segurança alimentar global e na preservação ambiental. A IA surge como uma força disruptiva que está redefinindo a abordagem aos desafios agrícolas, oferecendo não apenas segurança alimentar, mas também a oportunidade de reduzir o impacto ambiental da agricultura. Essa interseção entre a relevância da agricultura e o potencial da IA torna este tema de pesquisa essencial para abordar questões cruciais em nossa sociedade globalizada e voltada para o futuro.

Este estudo não abrange todas as aplicações práticas da IA na agricultura, mas se concentra em estabelecer os princípios fundamentais da IA de maneira estruturada. O objetivo é oferecer suporte para a avaliação dos conceitos aplicados na agricultura e preparar o terreno para futuras análises especializadas sobre implementações bem-sucedidas da IA na agricultura.

## **2 REVISÃO DE LITERATURA**

### **2.1 Fundamentos da inteligência artificial**

A principal incumbência de um sistema equipado com inteligência artificial é desempenhar funções de maneira equivalente ou superior à capacidade humana. Nesse contexto, é possível identificar algumas características fundamentais desses sistemas, tais como a habilidade de raciocínio (aplicar regras lógicas a um conjunto de dados disponíveis para chegar a uma conclusão), aprendizado (assimilar conhecimento a partir de erros e acertos, aprimorando-se para ações mais eficazes no futuro), reconhecimento de padrões (tanto visuais e sensoriais quanto de comportamento) e inferência (aplicar o raciocínio de forma adaptativa às situações do cotidiano) (VASCONCELOS e MARTINS JUNIOR, 2009).

A aprendizagem automática, conhecida como *machine learning* em inglês, constitui um subcampo da ciência da computação que se originou do estudo do reconhecimento de padrões e da teoria da aprendizagem computacional em inteligência artificial (MITCHELL, 1997). Sendo uma área da inteligência artificial voltada para o desenvolvimento de técnicas computacionais relacionadas ao aprendizado, assim como para a construção de sistemas capazes de adquirir conhecimento de maneira automática. Um sistema de aprendizado é um programa de computador que toma decisões com base em experiências acumuladas por meio da resolução bem-sucedida de problemas anteriores. Os diversos sistemas de aprendizado de máquina apresentam características distintas e compartilhadas que possibilitam sua classificação quanto à linguagem de descrição, modo, paradigma e método de aprendizado utilizado (MONARD e BARANAUSKAS, 2003).

Os algoritmos de *machine learning* buscam identificar padrões em conjuntos de dados, utilizando para isso diversas abordagens distintas. Em termos gerais, as tarefas de aprendizado de máquina são comumente classificadas em três amplas categorias, as quais dependem da natureza do "sinal" ou "*feedback*" de aprendizado disponível para um sistema de aprendizado (RUSSELL e NORVING, 1995).

Aprendizagem supervisionada envolve apresentar ao computador exemplos de inputs e outputs desejados fornecidos por um "professor", com o objetivo de que o sistema aprenda uma regra geral que mapeia os inputs para os outputs. Na aprendizagem não supervisionada, o algoritmo de aprendizado não recebe nenhum tipo de etiqueta, permitindo que ele descubra sozinho estruturas nos inputs. Esse tipo de aprendizagem pode ser um objetivo em si mesmo, buscando descobrir novos padrões nos dados, ou um meio para atingir um determinado fim. Já a aprendizagem por reforço envolve um programa de computador interagindo com um

ambiente dinâmico, no qual deve realizar um objetivo específico, sem que um professor o informe explicitamente se está se aproximando desse objetivo ou não (ALVES, SANTOS, *et al.*).

## **2.2 Algoritmos e técnicas relevantes**

As possibilidades de aplicação da inteligência artificial (IA) na agricultura são vastas e têm o potencial de transformar significativamente a condução das operações agrícolas. A seguir, apresento algumas das principais aplicações.

### **2.2.1 Redes Neurais Artificiais (RNAs)**

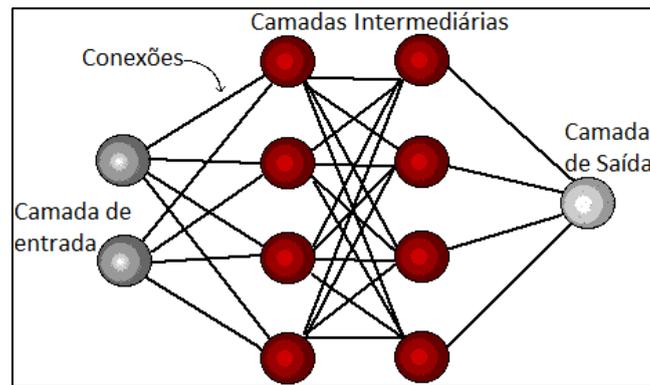
As Redes Neurais Artificiais (RNA) são modelos matemáticos que se inspiram nas estruturas neurais biológicas, adquirindo capacidade computacional por meio de aprendizado. O processamento da informação em uma RNA ocorre nos neurônios artificiais, conhecidos como neurônios de McCulloch e Pitts, também chamados de modelo MCP (MCCULLOCH e PITTS, 1943).

A maioria dos modelos de redes neurais incorpora uma regra de treinamento, na qual os pesos das conexões são ajustados com base nos padrões apresentados. Em outras palavras, elas aprendem por meio de exemplos. As arquiteturas neurais são geralmente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada subsequente (ICMC-USP, 2016).

Conforme ICMC-USP (2016), as camadas costumam ser tipicamente agrupadas em três categorias. Estas são listadas a seguir e ilustradas na Figura 1. São elas:

- Camada de Entrada: Nesta camada, os padrões são introduzidos na rede.
- Camadas Intermediárias ou Ocultas: Esta é a região onde a maior parte do processamento ocorre, através das conexões ponderadas; essas camadas podem ser consideradas extratoras de características.
- Camada de Saída: Nesta camada, o resultado é concluído e apresentado.

**Figura 1 - Modelo de Rede Neural Artificial - Perceptron de Múltiplas Camadas (MLP) (ICMC-USP, 2016).**



### 2.2.2 Árvores de Decisão

É utilizado para derivar modelos que definem com precisão classes significativas de dados dentro de um conjunto de dados específico. O processo de classificação compreende duas etapas. Na primeira etapa, o modelo é construído por meio da aplicação de um algoritmo de classificação no conjunto de dados de treinamento. Na segunda etapa, o modelo gerado é testado em um conjunto de dados de teste predefinido para avaliar o desempenho e a precisão do modelo treinado. Portanto, a classificação é o procedimento de atribuir rótulos de classe a partir de um conjunto de dados cujos rótulos de classe são desconhecidos (NIKAM, 2015).

Dentre os diversos métodos de aprendizado de máquina, a Árvore de Decisão ganhou considerável popularidade, sendo amplamente adotada na literatura. Além de sua intuitividade, facilidade de interpretação e capacidade de ser representada de duas maneiras (graficamente ou por meio de regras), algumas características adicionais atribuídas às Árvores de Decisão incluem: competitividade em relação a modelos computacionais mais complexos em termos de acurácia; incorporação de um método de seleção de atributos, proporcionando interpretabilidade ao modelo; robustez e escalabilidade; capacidade de lidar com atributos contínuos e discretos; processos de inferência e indução com baixo custo computacional (COPPIN, 2010; MITCHELL, 1997; QUINLAN, 1992).

### 2.2.3 Aprendizado Profundo (*Deep Learning*)

Uma subárea significativa do campo de aprendizado de máquina é denominada *Deep Learning* (DL), ou aprendizado profundo. Nesta abordagem, redes neurais artificiais, que possuem a capacidade de organizar estruturas denominadas neurônios de maneira análoga ao cérebro humano, são empregadas para o reconhecimento e controle eficiente de padrões e percepções (HAYKIN, 2001).

O DL emprega algoritmos de aprendizado de máquina que operam em múltiplos níveis, apresentando diferentes graus de abstração. Esses modelos aprendidos representam conceitos em vários níveis, em que os conceitos de alto nível são derivados dos níveis inferiores. Os conceitos de nível inferior, por sua vez, contribuem para a definição de vários conceitos de nível superior, promovendo a aprendizagem de múltiplos níveis de representação e abstração. Essa abordagem é fundamental para conferir significado a dados como imagens, sons e textos (RIBEIRO e HOSAKI, 2021).

Nos últimos dez anos, as ferramentas de DL têm provocado uma significativa transformação na área de visão computacional. Isso se deve, principalmente, à disponibilidade de extensas bases de dados contendo milhares de imagens e ao desenvolvimento de computadores capazes de reduzir significativamente o tempo necessário para processar essas bases de dados (PONTI e COSTA, 2017).

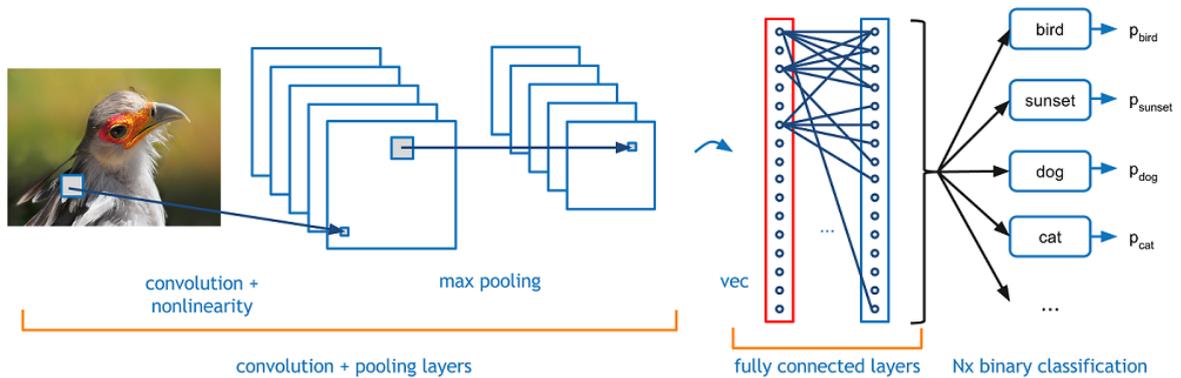
#### **2.2.4 Redes Neurais Convolucionais**

As Redes Neurais Convolucionais (CNNs) são um tipo específico de Rede Neural Artificial (ANN) originado a partir das propostas do pesquisador francês Yann LeCun e sua equipe em 1998. Desde sua concepção, as CNNs têm demonstrado grande eficácia na resolução de problemas de classificação, emergindo como uma alternativa viável aos métodos tradicionais para abordar esse tipo específico de desafio (LECUN, BOTTOU, *et al.*, 1998).

Estas redes apresentam uma estrutura geralmente organizada em camadas, incluindo as conhecidas como camadas de convolução. Estas desempenham o papel crucial na identificação de características presentes na imagem. Podem ser visualizadas como filtros que percorrem a imagem, cada um procurando por uma característica específica. Tais características incluem elementos abstratos compartilhados por todas as imagens, como bordas retas, curvaturas específicas, cores simples, entre outros (DESHPANDE, 2016)

A concepção envolve o uso de uma camada de rede neural totalmente conectada para classificar a imagem com base nas características identificadas e mapeadas nas camadas de convolução, como ilustrado na Figura 2.

**Figura 2** - Estrutura de uma Rede Neural Convolucional voltada para tarefas de classificação.



**Fonte:** (DESHPANDE, 2016)

Geralmente, a estrutura fundamental de uma CNN consiste em camadas intercaladas de convolução e pooling, seguidas por uma ou mais camadas totalmente conectadas. Quando se trata de redes de convolução para segmentação de imagem, as camadas totalmente conectadas (FC) são substituídas por uma camada final de convolução, resultando na denominação de Redes Totalmente Convolucionais (FCN) (LONG; SHELHAMER; DARRELL, 2015).

O sistema de detecção de objetos YOLO<sup>1</sup> utiliza redes neurais convolucionais (CNN) para treinar e detectar objetos. Uma CNN básica é composta por quatro operações principais conhecidas como convolução, não-linearidade, pooling ou subamostragem e classificação. Cada imagem pode ser representada como uma matriz tridimensional de valores de pixel com base em suas características visuais (PARTEL, KAKARLA e AMPATZIDIS, 2019).

### 3 METODOLOGIA

Este estudo derivou de uma revisão bibliográfica de natureza analítica sobre a aplicação da inteligência artificial nos sistemas de produção agrícola. A coleta de dados ocorreu no período de 01 a 15 de dezembro de 2023, utilizando como fonte a base de dados *Science Direct*. O critério de inclusão foi estabelecido para abranger artigos publicados entre 2019 e 2023, com o objetivo de incorporar informações atualizadas sobre o tema, além de selecionar aqueles que têm potencial aplicação atualmente ou que possam orientar estudos futuros.

---

<sup>1</sup> YOLO, que significa "You Only Look Once," é um framework de detecção de objetos em tempo real que realiza a detecção e classificação de objetos em uma única passagem pela rede neural. Ele divide a imagem em uma grade e atribui caixas delimitadoras e probabilidades de classe a cada célula dessa grade, permitindo uma detecção eficiente em várias escalas. O YOLO é conhecido por sua capacidade de lidar com sobreposição de objetos e é amplamente utilizado em aplicações como sistemas de vigilância e veículos autônomos (REDMON, DIVVALA, *et al.*, 2016).

Outro parâmetro relevante refere-se aos descritores utilizados. Foram considerados artigos que apresentassem termos como "*agriculture production systems*" e "*artificial intelligence*". A pesquisa resultou em artigos de pesquisa, dos quais foram selecionadas as seguintes revistas: *Computers and Electronics in Agriculture*, *Engineering Applications of Artificial Intelligence*, *Smart Agricultural Technology* e *Artificial Intelligence in Agriculture*.

Na *Science Direct*, dentre os 588 artigos encontrados, distribuídos conforme quadro 1, foram escolhidos 10 com base na leitura dos resumos, selecionando aqueles cujos temas mais se alinhavam ao objeto da pesquisa. Após a seleção conforme os critérios predefinidos, o estudo seguiu uma sequência de passos, incluindo leitura exploratória dos resumos para escolha do material alinhado aos objetivos, leitura completa dos artigos cujo o resumos melhor contribuíam com a revisão, finalizando com 10 trabalhos.

**Quadro 1 - Distribuição do resultado da busca por revista**

| Revista  | Quantidade |
|--|------------|
| <i>Computers and Electronics in Agriculture</i>            | 368        |
| <i>Engineering Applications of Artificial Intelligence</i> | 88         |
| <i>Smart Agricultural Technology</i>                       | 70         |
| <i>Artificial Intelligence in Agriculture</i>              | 62         |

Fonte: Elaborado pelo autor.

Após essas etapas, consolidou-se um corpus do estudo agrupando os temas mais abordados em duas categorias principais: "Aplicações da inteligência artificial na agricultura" e "Tecnologias emergentes". Com base nos autores selecionados e em suas experiências teóricas e práticas, foram derivadas conclusões que contribuem para uma compreensão mais aprofundada do tema em estudo.

## 4 RESULTADOS E DISCUSSÕES

Com o objetivo de identificar o uso de inteligência artificial na agricultura, foi realizada uma síntese dos 10 artigos selecionados, destacando os principais objetivos, metodologia e resultados de cada estudo para o tema, conforme tabela 1.

**Tabela 1** - Artigos de pesquisa selecionados na *Science Direct*.

| # | TÍTULO   | AUTOR   | OBJETIVO  | METODOLOGIA   | CONCLUSÃO  | DOI   |
|---|--|---|---|---|--|---|
| 1 | <i>An expert system for insect pest population dynamics prediction</i>   | Eric A. Ibrahim, Daisy Salifu, Samuel Mwalili, Thomas Dubois, Richard Collins, Henri E.Z. Tonnang | O estudo visa abordar o aumento da produção de abacate no Quênia, com foco nas fazendas de pequenos e grandes agricultores, identificando a infestação por insetos-praga como um desafio principal, causando perdas diretas e barreiras comerciais. | Foram coletados dados de contagens semanais de armadilhas para pragas em pomares de abacate entre setembro de 2017 e dezembro de 2020 no Quênia. O estudo utilizou redes neurais difusas (FNN) para modelar a dinâmica populacional das moscas-das-frutas <i>Bactocera dorsalis</i> e <i>Ceratitis</i> spp., considerando variáveis como contagens semanais de pragas, pluviosidade, temperatura média, umidade relativa e estágios fisiológicos das plantas. | Os modelos FNN mostraram resultados satisfatórios na previsão da dinâmica das pragas nos pomares, com a maioria dos modelos obtendo $R^2 > 0,85$ . O estudo destaca a eficácia desses modelos como ferramentas preditivas para o manejo e controle de populações de moscas-das-frutas em plantações de abacate. Além disso, ressalta a aplicabilidade desses modelos em prever pragas em sistemas de cultivo similares, oferecendo a possibilidade de implementar medidas de controle, como o uso de biocontrole, com base em valores de limiar. | <a href="https://doi.org/10.1016/j.compag.2022.107124">https://doi.org/10.1016/j.compag.2022.107124</a> |
| 2 | <i>An optimized dense convolutional neural network model for disease recognition and classification in corn leaf</i> | Abdul Waheed, Muskan Goyal, Deepak Gupta, Ashish Khanna, Aboul Ella Hassanien, Hari Mohan Pandey  | Propor uma arquitetura otimizada de rede neural convolucional densa (DenseNet) para reconhecimento e classificação de doenças nas folhas de milho, visando melhorar a produção agrícola ao monitorar a saúde das colheitas.                         | Implementação da arquitetura DenseNet otimizada utilizando aprendizado profundo para lidar com a falta de diferenciação de sintomas nas fases iniciais das doenças. Avaliação do desempenho em acurácia, comparando-o com outras arquiteturas de CNN como EfficientNet, VGG19Net, NASNet e Xception Net. Consideração das medidas de qualidade, tempo e acurácia.   | O modelo DenseNet otimizado alcançou 98,06% de acurácia, superando outras arquiteturas de CNN. Utiliza significativamente menos parâmetros e tempo computacional. Indica que o modelo proposto é uma opção eficaz e eficiente para o reconhecimento e classificação de doenças nas folhas de milho, contribuindo para o monitoramento da saúde das colheitas e melhorando a produção agrícola em quantidade e qualidade.   | <a href="https://doi.org/10.1016/j.compag.2020.105456">https://doi.org/10.1016/j.compag.2020.105456</a> |

|   |  |   |  |   |   |   |
|---|--|---|--|---|---|---|
| 3 | <i>UAV-based high-throughput phenotyping and selection accuracy in maize varieties under artificial MSV inoculation</i>              | Walter Chivasa, Onesimo Mutanga, Juan Burgueño        | O objetivo deste estudo foi desenvolver um protocolo para prever a incidência do vírus do mosaico do milho (MSV) e o rendimento de grãos usando dados multiespectrais derivados de veículos aéreos não tripulados (UAV). Além disso, buscou-se identificar as variáveis preditoras adequadas e os estágios fenológicos ideais para a predição do MSV e do rendimento de grãos. | Vinte e cinco variedades de milho foram avaliadas sob inoculação artificial de MSV. Medidas manuais e imagens multiespectrais foram obtidas nos estágios vegetativo, floração e enchimento de grãos. Dados derivados de UAV foram adquiridos nas bandas multiespectrais de Verde (0,53–0,57 µm), Vermelho (0,64–0,68 µm), Vermelho-edge (0,73–0,74 µm) e Infravermelho Próximo (0,77–0,81 µm). Oito índices de vegetação foram determinados, incluindo NDVI, NDVired-edge, GNDVI, SR, CIgreen, CIred-edge, SAVI e OSAVI. Finalmente, foram realizadas previsões de MSV e rendimento de grãos com 36 modelos usando regressão múltipla, árvores de decisão e regressão linear. | Os resultados indicam que a sensoriamento remoto multiespectral baseado em UAV é uma ferramenta confiável para a fenotipagem da doença MSV e a previsão do rendimento de grãos. As variáveis frequentemente selecionadas para a predição do MSV incluíram a banda Verde no estágio vegetativo (61,5%), a banda Vermelha no estágio vegetativo (68,4%) e de floração (80,4%), e GNDVI no estágio vegetativo (88,7%). Os melhores preditores de MSV foram GNDVI (r = 0,84; RMSE = 0,85), CIgreen (r = 0,83; RMSE = 0,86) e a banda Vermelha (r = 0,77; RMSE = 0,99) medidos no estágio vegetativo. Seis dos 36 modelos foram selecionados como ideais para prever o rendimento de grãos de milho, sendo o estágio vegetativo o mais ideal para a predição tanto do MSV quanto do rendimento de grãos. | <a href="https://doi.org/10.1016/j.compag.2021.106128">https://doi.org/10.1016/j.compag.2021.106128</a> |
| 4 | <i>Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence</i> | Victor Partel, Sri Charan Kakarla, Yiannis Ampatzidis | Desenvolver um pulverizador inteligente para aplicação eficiente de agroquímicos, reduzindo desperdícios, custos, riscos de danos às culturas e impactos ambientais.   | Projeto de um pulverizador inteligente usando visão computacional e inteligência artificial para identificar e pulverizar seletivamente plantas-alvo. Dois cenários experimentais foram criados para avaliação, um com plantas artificiais e outro com plantas  | A GPU mais poderosa alcançou 71% de precisão e 78% de recall em plantas reais, e 91% de precisão em plantas artificiais. A GPU menos poderosa teve 90% de precisão em plantas artificiais, mas desempenho inferior (59% de precisão) em plantas reais. A adição de um   | <a href="https://doi.org/10.1016/j.compag.2018.12.048">https://doi.org/10.1016/j.compag.2018.12.048</a> |

|   |   |   |   |   |  |   |
|---|---|---|---|---|--|---|
|   |   |   |   | reais, usando diferentes unidades de processamento gráfico (GPU).   | GPS RTK permitiu a geração automática de mapas de ervas daninhas, demonstrando uma tecnologia inteligente integrada que pode reduzir significativamente o uso de agroquímicos, custos e impactos ambientais.   |   |
| 5 | <i>A mixed-autonomous robotic platform for intra-row and inter-row weed removal for precision agriculture</i>           | Francesco Visentin, Simone Cremasco, Marco Sozzi, Luca Signorini, Moira Signorini, Francesco Marinello, Riccardo Muradore | Este trabalho visa abordar o problema persistente das plantas daninhas na agricultura, apresentando uma solução inovadora baseada em robôs para melhorar a eficácia e sustentabilidade no controle de plantas daninhas. | O sistema proposto é um sistema robótico misto-autônomo com uma plataforma integrada de três eixos e um sistema de visão em um <i>rover</i> móvel. Controlado remotamente por um operador humano, o sistema usa câmeras RGB-D para identificar e classificar solo, cultura principal e plantas daninhas, com uma Rede Neural Profunda pré-treinada. A remoção das plantas daninhas é realizada após confirmação da classificação. | Os testes em laboratório, campo aberto e estufa mostram que o sistema alcança uma identificação acima de 95% para plantas, com eficácia de remoção de plantas daninhas até 85% e danos à cultura principal inferior a 5%. A abordagem robótica mista-autônoma oferece uma solução promissora para o controle de plantas daninhas, superando limitações das técnicas convencionais e contribuindo para práticas agrícolas mais sustentáveis e eficientes. | <a href="https://doi.org/10.1016/j.compag.2023.108270">https://doi.org/10.1016/j.compag.2023.108270</a> |
| 6 | <i>Using artificial intelligence algorithms to predict rice (Oryza sativa L.) growth rate for precision agriculture</i> | Li-Wei Liu, Xingmao Ma, Yu-Min Wang, Chun-Tang Lu, Wen-Shin Lin   | O estudo visa prever a taxa de crescimento do arroz para aprimorar a agricultura de precisão, utilizando dados de três cultivares em diferentes regiões de Taiwan.  | Foram analisados 10.246 dados de crescimento de 95 cultivos, empregando algoritmos de regressão, redes neurais artificiais (ANN) e programação de expressão genética (GEP). A simulação considerou a temperatura ambiente e a estação de crescimento como variáveis de entrada.   | Os modelos não-lineares baseados em inteligência artificial, especialmente ANN e GEP, superaram o modelo de regressão. O GEP-Trall foi recomendado devido à sua precisão, especialmente nas fases de transição, e à menor demanda de hardware em comparação com ANN. Houve redução significativa nos erros médios absolutos e nos erros  | <a href="https://doi.org/10.1016/j.compag.2021.106286">https://doi.org/10.1016/j.compag.2021.106286</a> |

|   |   |   |  |   |   |   |
|---|---|---|--|---|---|---|
|   |   |   |  |   | quadráticos médios em relação ao modelo de regressão.   |   |
| 7 | <i>AgriPrediction: A proactive internet of things model to anticipate problems and improve production in agricultural crops</i> | Uélison Jean L. dos Santos, Gustavo Pessin, Cristiano André da Costa, Rodrigo da Rosa Righi | O artigo aborda o desafio global de garantir alimentos para todos, propondo aumentar a produção agrícola. Destaca a necessidade de inovação, especialmente através do uso da Internet das Coisas (IoT) no ambiente rural.  | O estudo propõe um modelo chamado AgriPrediction, que combina tecnologia IoT LoRa e um modelo de previsão ARIMA. A metodologia visa antecipar disfunções nas safras, notificando os agricultores para ações corretivas imediatas. Os resultados indicam a viabilidade do uso do LoRa em áreas rurais e benefícios significativos, particularmente no cultivo de rúcula.   | O AgriPrediction demonstra eficácia ao antecipar problemas nas colheitas e alertar os agricultores. Os resultados específicos mostram melhorias notáveis no desenvolvimento das folhas e no peso das colheitas ao utilizar o modelo. Conclui-se que a combinação de tecnologia LoRa e modelo ARIMA é promissora para melhorar a produção agrícola e enfrentar desafios alimentares futuros. | <a href="https://doi.org/10.1016/j.compag.2018.10.010">https://doi.org/10.1016/j.compag.2018.10.010</a> |
| 8 | <i>Quantifying the relationships of soil properties and crop growth with yield in a NPK fertilizer application maize field</i>  | Yue Zhang, Chenzhen Xia, Xingyu Zhang, Ye Sha, Guozhong Feng, Qiang Gao                     | O estudo buscou analisar a variabilidade espacial de propriedades do solo, desempenho da cultura, gestão de fertilização e métodos de preparo do solo, visando melhorar a previsão e o rendimento agrícola. O foco foi delinear zonas de gestão específicas (MZs) considerando essa variabilidade e investigar suas relações com o rendimento. | Um campo de milho na China foi escolhido para coleta de amostras de solo e cultura em 2019 e 2020. A área foi dividida em MZs retangulares com base na variabilidade espacial. Correlações entre propriedades do solo, desempenho da cultura e rendimento foram analisadas em diferentes MZs e estágios de crescimento. Modelos de previsão de rendimento foram desenvolvidos usando o modelo de floresta aleatória (RF). | O campo foi dividido em três MZs com características homogêneas. As correlações entre fatores variaram entre MZs, estágios e anos. O modelo RF teve bom desempenho, destacando a importância da variabilidade espacial na gestão de nutrientes. O estudo sugere oportunidades para a implementação de práticas de gestão de nutrientes específicas em campos de milho.                      | <a href="https://doi.org/10.1016/j.compag.2022.107011">https://doi.org/10.1016/j.compag.2022.107011</a> |
| 9 | <i>Impurity monitoring study for corn kernel harvesting based on machine vision and CPU-Net</i>                                 | Lei Liu, Yuefeng Du, Du Chen, Yubo Li, Xiaoyu Li, Xiaoning Zhao, Guorun Li, Enrong Mao      | A pesquisa tem como objetivo avaliar a qualidade da operação de colheitadeiras de milho por meio da métrica da taxa de impureza do grão, enfrentando desafios como ambientes   | A abordagem incluiu o design de um dispositivo de monitoramento baseado em visão computacional para garantir a transferência eficaz de material e a criação de um modelo de regressão linear para   | Os resultados experimentais indicaram que a rede CPU-Net teve a melhor performance, com alta precisão de segmentação (MIoU, MPA) e eficiência de processamento (ST). O monitoramento em tempo real  | <a href="https://doi.org/10.1016/j.compag.2022.107436">https://doi.org/10.1016/j.compag.2022.107436</a> |

|    |  |  |   |   |   |   |
|----|--|--|---|---|---|---|
|    |  |  | complexos e iluminação instável.  | calcular a taxa de impureza. Foi proposto um modelo de segmentação semântica CPU-Net, integrando módulos de atenção e pooling, e vários modelos foram treinados usando um conjunto personalizado de imagens de milho.   | das impurezas fornece uma base para ajustar parâmetros operacionais, melhorando a eficiência e qualidade da colheita e reduzindo perdas econômicas.   |   |
| 10 | <i>Airborne hyperspectral imaging for early diagnosis of kimchi cabbage downy mildew using 3D-ResNet and leaf segmentation</i> | Lukas Wiku Kuswidiyanto, Pingan Wang, Hyun-Ho Noh, Hee-Young Jung, Dae-Hyun Jung, Xiongzhe Han | Desenvolver um método de detecção precoce da doença do míldio em kimchi na Coreia, utilizando imagens hiperespectrais obtidas por um UAV e uma câmera hiperespectral. | Utilização de modelos de rede neural convolucional tridimensional (3D-CNN), especificamente a Rede Residual 3D (3D-ResNet) com quatro blocos residuais, ReLU e max-pooling. Busca-se uma detecção eficaz considerando características espectrais e espaciais da doença. | O modelo 3D-ResNet, combinado com tecnologia de imagem hiperespectral e UAV, alcançou 87.6% de precisão global e 87.3% de precisão para plantas doentes. Estimativa da severidade da doença utilizando agrupamento espacial resultou em um erro relativo de 27.07% ou uma diferença de nível de 1.08 em relação aos valores reais. Esses resultados destacam a eficácia da abordagem para monitoramento não destrutivo de doenças em escala de campo. | <a href="https://doi.org/10.1016/j.compag.2023.108312">https://doi.org/10.1016/j.compag.2023.108312</a> |

Fonte: Elaborado pelo autor.

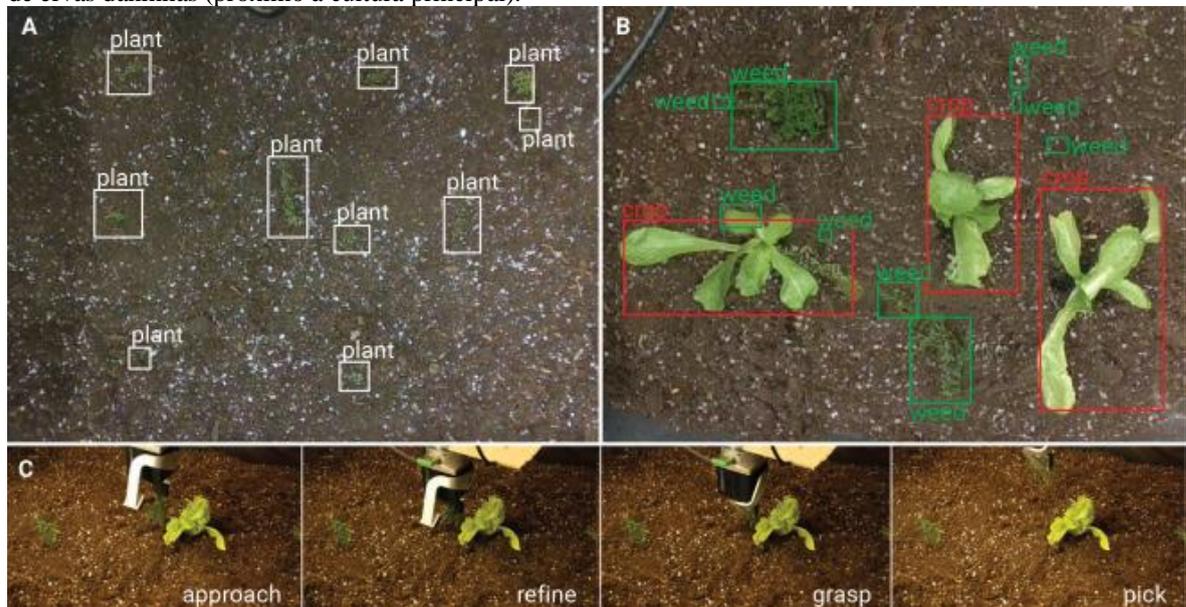


No intuito de reduzir a tarefas que geralmente são realizadas manualmente e assim mitigar uso de herbicidas Quan, *et al.* (2019) e Shah, *et al.* (2021) por meio de um conjunto de dados agrícolas composto por 20.000 imagens de plântulas de cultivares e ervas daninhas adquiridas por um robô em campo, abrangendo diversas fases fenológicas e variações de ângulos nas fotografias, aplicou-se uma Rede Neural Convolucional (R-CNN) utilizando processamento de imagens. O resultado demonstrou uma acurácia excelente na detecção de cultivares e ervas daninhas.

Foi desenvolvido e avaliado um protótipo de pulverizador inteligente usando inteligência artificial (IA). O sistema inclui software de visão computacional baseado em aprendizado profundo para detectar ervas daninhas específicas e hardware com 12 bicos de pulverização rápida. Com componentes acessíveis, o custo total é inferior a \$1.500. A avaliação com plantas reais mostrou que a GPU GTX 1070 Ti teve melhor desempenho do que a TX2 GPU. A precisão e recall do sistema de detecção e pulverização aumentaram significativamente com a GPU GTX 1070 Ti. O pulverizador demonstrou capacidade para distinguir com precisão entre alvos e não alvos. Um mapa de ervas daninhas foi gerado usando o pulverizador e um RTK GPS, mostrando potencial para uma agricultura mais produtiva e sustentável, especialmente diante de desafios como escassez de mão de obra e mudanças climáticas (PARTEL, KAKARLA e AMPATZIDIS, 2019).

A remoção de ervas daninhas é um desafio na agricultura, usualmente tratado por meio de técnicas com o uso de plantas de cobertura ou cobertura do solo, uso de defensivos químicos ou controle mecânico. O artigo “*A mixed-autonomous robotic platform for intra-row and inter-row weed removal for precision agriculture*” apresenta um sistema robótico semi-autônomo para controle mecânico de ervas daninhas em plantações. O sistema inclui um *rover* controlado remotamente e um sistema robótico autônomo com visão computacional e inteligência artificial para detecção e remoção de ervas daninhas conforme figura 4. Embora em fase de protótipo, o robô já demonstrou a capacidade de identificar e remover com precisão as plantas daninhas. Melhorias potenciais incluem aprimoramentos no sistema de controle, navegação e identificação. A implementação de novos sensores pode tornar o sistema totalmente autônomo, proporcionando uma solução eficiente, além de ecológica e segura para os produtores rurais. Este protótipo bem-sucedido estabelece o caminho para mais pesquisas visando aperfeiçoar a eficiência e sustentabilidade nas operações agrícolas (VISENTIN, CREMASCO, *et al.*, 2023).

**Figura 4** - (A) Identificação de plantas-alvo. (B) Localização autônoma de plantas daninhas. Caixas vermelhas contêm plantas cultivadas que devem permanecer intocadas durante o processo de remoção de ervas daninhas. Caixas verdes, por outro lado, indicam a localização das ervas daninhas. (C) Um exemplo de remoção complexa de ervas daninhas (próximo à cultura principal).



Fonte: (VISENTIN, CREMASCO, *et al.*, 2023).

Neste estudo “*An optimized dense convolutional neural network model for disease recognition and classification in corn leaf*”, foi apresentada uma arquitetura otimizada de rede neural densa (*DenseNet*) para identificação e classificação de doenças foliares do milho. Onde foi comparado diversas arquiteturas existentes, delineando suas vantagens e desvantagens. O modelo proposto conseguiu uma precisão notável de 98,06% na identificação de três tipos de doenças na cultura do milho. Utilizamos um *big data*<sup>2</sup> e aplicando técnicas de aumento para aprimorar a generalização do modelo. Os resultados foram superiores às arquiteturas de CNN comparadas em precisão, parâmetros e tempo de treinamento. A abordagem de aprendizado a partir da imagem de entrada mostrou-se mais eficiente do que métodos tradicionais. Este trabalho sugere a possibilidade de expansão para identificação de mais doenças, buscando uma modelagem mais eficiente. Futuramente, possível desenvolvimento de um aplicativo móvel para identificação de doenças em folhas da cultura do milho (WAHEED, GOYAL, *et al.*, 2020).

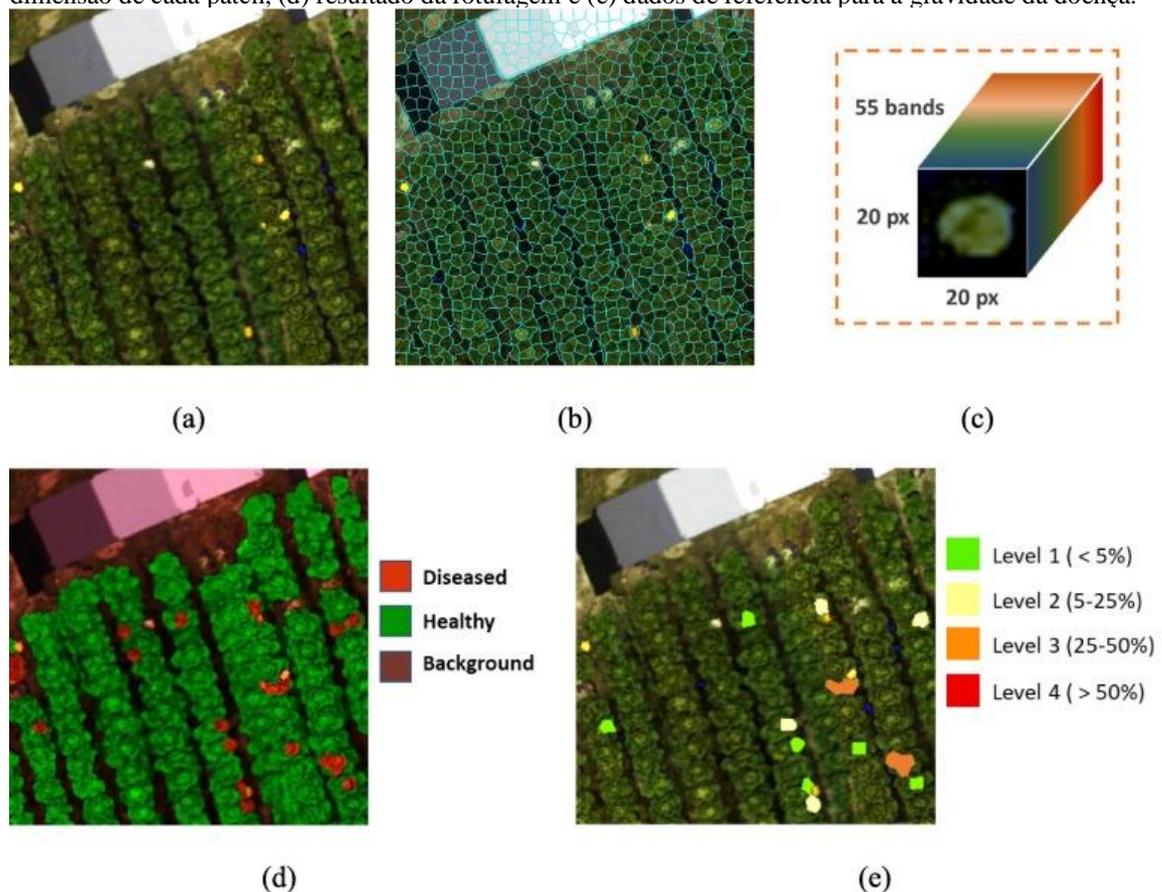
Ainda sobre CNN o estudo “*Airborne hyperspectral imaging for early diagnosis of kimchi cabbage downy mildew using 3D-ResNet and leaf segmentation*” desenvolveu um sistema automático de diagnóstico para a doença de míldio nas folhas de kimchi, substituindo

<sup>2</sup> Mayer-Schonberg e Cukier (2013) deram uma definição de big data, ao qual se referiram como o processo de extração de informações de alta qualidade a partir de grandes quantidades de informações.

o método tradicional que é trabalhoso e propenso a erros humanos. O sistema utiliza um sistema hiperespectral aéreo para monitoramento eficiente do campo, permitindo a detecção precoce da doença. Uma rede neural convolucional 3D-ResNet alcançou uma precisão geral de 87,6% e precisão de 87,3% na classificação de doenças. Embora viável, a necessidade de pessoal treinado e o custo do sistema são considerações importantes. Futuros estudos visam reduzir o número de bandas para tornar o modelo mais eficiente e testar sua robustez em diferentes condições e campos (KUSWIDIYANTO, WANG, *et al.*, 2023).

A Figura 5 mostra um segmento do campo visualizado nas bandas RGB (a), os limites gerados pelo algoritmo SLIC<sup>3</sup> (b) e a imagem gerada após a rotulagem (d). Cada segmento é um patch do cubo hiperespectral com o tamanho de 20 pixels  $\times$  20 pixels  $\times$  55 bandas (altura  $\times$  largura  $\times$  profundidade), como mostrado na Figura 8c.

**Figura 5** - Uma seção do campo visualizado em (a) bandas RGB, (b) limites gerados pelo algoritmo SLIC, (c) dimensão de cada patch, (d) resultado da rotulagem e (e) dados de referência para a gravidade da doença.



Fonte: (KUSWIDIYANTO, WANG, *et al.*, 2023).

<sup>3</sup> Simple Linear Iterative Clustering (SLIC). SLIC é um algoritmo de agrupamento de pixels, ele adapta uma abordagem de agrupamento k-means para gerar superpixels de forma eficiente (ACHANTA, SHAJI, *et al.*, 2012).

Já no trabalho intitulado “*Impurity monitoring study for corn kernel harvesting based on machine vision and CPU-Net*” foi desenvolvido um dispositivo de monitoramento de impurezas no milho, superando desafios como o ambiente de colheita complexo, luz instável, alta frequência de vibração do corpo do colhedor e outros fatores. Utilizando o modelo CPU-Net, baseado em aprendizado profundo, obteve uma precisão de 97,31% na detecção de impurezas. A taxa de processamento foi rápida (5-8 FPS), fornecendo suporte para a monitorização online da taxa de impurezas. Os dados em tempo real mostraram pequenas variações em relação às estatísticas manuais, com um erro médio de 4,64%, indicando eficácia na monitorização. Isso permite ajustes rápidos nos parâmetros do colhedor, melhorando a qualidade e eficiência da operação (LIU, DU, *et al.*, 2022).

## 5 CONSIDERAÇÕES FINAIS

A integração da Inteligência Artificial desempenha um papel crucial na transformação e otimização da agricultura. Técnicas como *Machine Learning*, *Deep Learning* e Redes Neurais são fundamentais nesse processo. Essas tecnologias oferecem uma variedade de aplicações que podem aprimorar significativamente a eficiência operacional e a produtividade no setor agrícola. O *Machine Learning*, por exemplo, é empregado para analisar grandes conjuntos de dados agrícolas, proporcionando insights valiosos sobre padrões climáticos, safras e condições do solo. Já as Redes Neurais, que são uma subcategoria do *Machine Learning*, baseiam-se no funcionamento do cérebro humano e são capazes de aprender e adaptar-se a dados complexos. Elas permitem a previsão de safras, identificação de pragas e otimização da distribuição de recursos, como água e fertilizantes.

A agricultura moderna está cada vez mais integrando tecnologias de IA para melhorar suas práticas e aumentar a eficiência. Através de técnicas como *Machine Learning*, *Deep Learning* e Redes Neurais, os agricultores podem analisar enormes conjuntos de dados agrícolas para entender padrões climáticos, otimizar o uso de recursos e prever safras com maior precisão. Além disso, sistemas de visão computacional são empregados para identificar pragas e doenças nas culturas, permitindo respostas rápidas para mitigar danos. A otimização de recursos, como água e fertilizantes, também é alcançada por meio de algoritmos de IA, que levam em conta variáveis como tipo de solo e condições climáticas para fornecer recomendações precisas e personalizadas. Essas aplicações da Inteligência

Artificial na agricultura não só aumentam a produtividade, mas também contribuem para uma gestão mais sustentável e eficiente das operações agrícolas.

Entretanto, apesar dos benefícios evidentes, a adoção plena da IA na agricultura enfrenta desafios importantes. Um dos principais obstáculos reside na acessibilidade e disponibilidade de dados confiáveis, uma vez que a qualidade dos resultados depende diretamente da quantidade e qualidade das informações utilizadas pelos algoritmos. Além disso, a resistência à adoção de novas tecnologias por parte dos agricultores, a falta de infraestrutura em algumas regiões agrícolas e as preocupações relacionadas à segurança de dados são aspectos que precisam ser superados. Assim, o acesso a dados confiáveis e a segurança deles são fundamentais para que a IA possa desempenhar plenamente seu papel transformador na agricultura, impulsionando uma produção mais sustentável e eficiente, capaz de atender às crescentes demandas globais por alimentos.

## 6 BIBLIOGRAFIA

ACHANTA, R. et al. SLIC superpixels compared to state-of-the-art superpixel methods. **IEEE Trans. Pattern Anal. Mach. Intell.**, v. 34, p. 2274-2282, 2012.

ALVES, K. D. et al. Inteligência artificial – aplicações e tendências. **Brazilian Journal of Development**, v. 9, n. 4, p. 12560–12576. ISSN 2525-8761.

COPPIN, B. **Inteligência Artificial**. [S.l.]: LTC, 2010.

DESHPANDE, A. A Beginner's Guide to Understanding Convolutional Neural. **Adit Deshpande Blog**, 2016. Disponível em: <<https://adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>>. Acesso em: 12 dezembro 2023.

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.

ICMC-USP. **Redes Neurais Artificiais**, 2016. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>>. Acesso em: 10 dez. 2023.

KUSWIDIYANTO, L. K. et al. Airborne hyperspectral imaging for early diagnosis of kimchi cabbage downy mildew using 3D-ResNet and leaf segmentation. **Computers and Electronics in Agriculture**, v. 214, 2023. ISSN 0168-1699.

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, 1998.

LIU, L. et al. Impurity monitoring study for corn kernel harvesting based on machine vision and CPU-Net. **Computers and Electronics in Agriculture**, v. 202, 2022. ISSN 0168-1699.

LOPES, M. A. Mais inteligência no campo. **Globo Rural**, 2023. Disponível em: <<https://globorural.globo.com/opiniao/vozes-do-agro/noticia/2023/05/mais-inteligencia-no-campo.ghtml>>. Acesso em: 2023 Setembro 14.

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

MEGETO, G. A. S. et al. Artificial intelligence applications in the agriculture 4.0. **Revista Ciência Agrônômica**, Fortaleza, 51, 2020. e20207701.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. Vendas externas do agronegócio somam US\$ 96,8 bilhões em 2019. **Siscomex**, 2022. Disponível em: <<https://www.gov.br/siscomex/pt-br/informacoes/demais-noticias-de-comercio-exterior/agricultura/vendas-externas-do-agronegocio-somam-us-968-bilhoes-em-2019#:~:text=Vendas%20externas%20do%20agroneg%C3%B3cio%20somam%20US%24%2096%2C8%20bilh%C3%B5es%20em%202019>>. Acesso em: 14 Setembro 2023.

- MITCHELL, T. **Machine Learning**. McGraw Hill. [S.l.]. 1997.
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas Inteligentes, Fundamentos e Aplicações**, v. 1, n. 1, 2003.
- NIKAM, S. S. A comparative study of classification techniques in data mining algorithms. **Oriental journal of computer science & technology**, v. 8, n. 1, p. 13–19, 2015.
- PARTEL, V.; KAKARLA, S. C.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 157, p. 339-350, 2019. ISSN 0168-1699.
- PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision: A systematic review. **Computers and Electronics in**, Amsterdam, v. 153, p. 69-81, Abril 2018.
- PONTI, M. A.; COSTA, G. B. P. Como funciona o Deep Learning. In: \_\_\_\_\_ **Tópicos em Gerenciamento de Dados e Informações, SBC**. 1ª. ed. [S.l.]: [s.n.], 2017.
- QUAN, L. et al. Maize seedling detection under different growth stages and complex field environments based on an improved Faster R–CNN. **Biosystems Engineering**, v. 184, p. 1-23, 2019.
- QUINLAN, J. R. **C4.5: Programs for Machine Learning**. [S.l.]: Morgan Kaufmann, 1992.
- R CORE TEAM. **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing. Vienna, Austria. 2022.
- REDMON, J. et al. You only look once: Unified, real-time object detection. **The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016. 779-788.
- RIBEIRO, D. F. R.; HOSAKI, G. Y. DEEP LEARNING Ensinando a aprender. **Revista de Gestão e Estratégia**, Assis-SP, v. 3, n. 1, 2021. ISSN 2674-6743.
- RUSSELL, S. **Artificial Intelligence: A Modern Approach**. 3ª. ed. London: Pearson, 2010.
- RUSSELL, S.; NORVING, P. Artificial A modern approach. **Artificial Intelligence. Prentice-Hall. Egnlewood Cliffs**, v. 25, n. 27, 1995.
- SHAH, T. M.; NASIKA, D. P. B.; OTTERPOHL, R. Plant and Weed Identifier Robot as an Agroecological Tool Using Artificial Neural Networks for Image Identification. **Agriculture**, v. 11, n. 222, 2021.
- TETILA, E. C. **Detecção e classificação de doenças e pragas da soja usando imagens de veículos aéreos não tripulados e técnicas de visão computacional**. Tese (Doutorado em Desenvolvimento Local) – Universidade Católica Dom Bosco (UCDB). Campo Grande, MS, p. 103. 2019.

UNITED NATIONS. World Population Prospects 2022: Summary of Results. **Department of Economic and Social Affairs**, 2022. Disponível em:

<[https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/un\\_desa\\_pd\\_2022\\_wpp\\_key-messages.pdf](https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/un_desa_pd_2022_wpp_key-messages.pdf)>. Acesso em: 14 Setembro 2023.

VASCONCELOS, V. V.; MARTINS JUNIOR, P. P. **Protótipo de sistema especialista para auxílio à decisão em direito ambiental: situações de desmatamentos rurais**. CEFET-MG. [S.l.]. 2009.

VISENTIN, F. et al. A mixed-autonomous robotic platform for intra-row and inter-row weed removal for precision agriculture. **Computers and Electronics in Agriculture**, v. 214, 2023. ISSN 0168-1699.

WAHEED, A. et al. An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. **Computers and Electronics in Agriculture**, v. 175, 2020. ISSN 0168-1699.