



**ANTONIO MENEGHETTI FACULDADE**

**BRUNO KAUÃ DE SIQUEIRA PINHEIRO**

**ANÁLISE DE ALGORITMOS DE IA PARA A DETECÇÃO DE DOENÇAS EM  
FOLHAS DE SOJA**

**RECANTO MAESTRO - RESTINGA SÊCA  
2024**

**BRUNO KAUÃ DE SIQUEIRA PINHEIRO**

**ANÁLISE DE ALGORITMOS DE IA PARA A DETECÇÃO DE DOENÇAS  
EM FOLHAS DE SOJA**

Trabalho de Conclusão de Curso, apresentado ao curso de Graduação em Sistemas de Informação da Antonio Meneghetti Faculdade - AMF, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Orientador: Prof. Ms. Rhauani Weber Aita Fazul

**RECANTO MAESTRO - RESTINGA SÊCA**

**2024**

**BRUNO KAUÃ DE SIQUEIRA PINHEIRO**

**ANÁLISE DE ALGORITMOS DE IA PARA A DETECÇÃO DE DOENÇAS  
EM FOLHAS DE SOJA**

Trabalho de Conclusão de Curso, apresentado ao curso de Graduação em Sistemas de Informação da Antonio Meneghetti Faculdade - AMF, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Orientador: Prof. Ms. Rhauani Weber Aita Fazul

Data de aprovação: \_\_/\_\_/\_\_\_\_

**Banca Examinadora:**

Orientador: \_\_\_\_\_

Ms. Rhauani Weber Aita Fazul  
Antonio Meneghetti Faculdade

Membro: \_\_\_\_\_

Ms. Gustavo Henrique Florencio  
Antonio Meneghetti Faculdade

Membro: \_\_\_\_\_

Dr. Marcelo Bortoluzzi Diaz  
Antonio Meneghetti Faculdade

Membro: \_\_\_\_\_

Dr. Felipe Becker Nunes  
Antonio Meneghetti Faculdade

## **AGRADECIMENTOS**

Gostaria de expressar meu sincero agradecimento a todos que colaboraram para a realização deste trabalho. Agradeço pela paciência e compreensão. Um especial obrigado aos professores, minha família e amigos pelo apoio constante.

*“Líder: um pouco se nasce, muito se torna”.*

Acadêmico Professor Antonio Meneghetti, 2009.

## RESUMO

A aplicação de inteligência artificial no agronegócio permite monitorar culturas de forma mais eficiente, identificando rapidamente a presença de doenças como a ferrugem asiática e possibilitando decisões assertivas para o manejo das lavouras. A identificação precoce dessa doença na lavoura contribui para um manejo mais eficiente, viabilizando intervenções rápidas que evitam a propagação dessa doença e, conseqüentemente, grandes perdas na produção. Esta pesquisa explora o uso da inteligência artificial no agronegócio, focando na aplicação de algoritmos de processamento e classificação para a análise de folhas de soja em diferentes estágios da ferrugem asiática. O principal objetivo é apresentar os processos e os resultados da implementação dessa tecnologia no setor agrícola, destacando os benefícios tanto para os produtores quanto para o meio ambiente. A pesquisa utiliza uma abordagem quantitativa para avaliar a precisão dos algoritmos com base nos dados fornecidos, proporcionando uma análise metódica da aplicabilidade dessas tecnologias no agronegócio. Os algoritmos de aprendizado de máquina, como *ResNet* e *Vision Transformers*, foram aplicados para classificar e identificar padrões de infecção em folhas de soja. Cada um dos algoritmos foi testado e avaliado em termos de acurácia, precisão e *recall*, o que permitiu uma análise detalhada da eficácia de cada técnica para a detecção de doenças. O estudo examina se o uso desses algoritmos pode trazer benefícios significativos para os produtores, melhorando a eficiência da detecção de doenças e, conseqüentemente, a gestão das culturas. Com a detecção automatizada, os produtores podem otimizar o uso de pesticidas, reduzindo custos e minimizando impactos ambientais. Os algoritmos testados como o *ResNet* e o *Vision Transformers* foram avaliados em termos de desempenho, e o *Vision Transformers* demonstrou uma alta eficácia na detecção de ferrugem asiática. Assim, ele está totalmente apto para ser implementado em uma aplicação real, visando a automação no monitoramento das lavouras. Dessa forma, a adoção da inteligência artificial no agronegócio pode contribuir para uma agricultura mais sustentável e produtiva, beneficiando tanto os agricultores quanto a sociedade em geral.

**Palavras-chave:** Agronegócio, Inteligência Artificial, Tecnologia, Ferrugem Asiática.

## ABSTRACT

The application of artificial intelligence in agribusiness allows for more efficient crop monitoring, quickly identifying the presence of diseases such as asian soybean rust and enabling assertive decisions for crop management. Early detection of this disease in crops contributes to more efficient management, facilitating rapid interventions that prevent its spread and, consequently, large production losses. This research explores the use of artificial intelligence in agribusiness, focusing on the application of processing and classification algorithms for analyzing soybean leaves at different stages of asian soybean rust. The main objective is to present the processes and results of implementing this technology in the agricultural sector, highlighting the benefits for both producers and the environment. The research uses a quantitative approach to assess the accuracy of the algorithms based on the provided data, offering a methodical analysis of the applicability of these technologies in agribusiness. Machine learning algorithms, such as ResNet and Vision Transformers, were applied to classify and identify infection patterns in soybean leaves. Each algorithm was tested and evaluated in terms of accuracy, precision, and recall, allowing for a detailed analysis of the effectiveness of each technique in disease detection. The study examines whether the use of these algorithms can bring significant benefits to producers by improving disease detection efficiency and, consequently, crop management. With automated detection, producers can optimize pesticide use, reducing costs and minimizing environmental impacts. The tested algorithms, such as ResNet and Vision Transformers, were evaluated for performance, and Vision Transformers demonstrated high effectiveness in detecting Asian rust. Thus, it is fully capable of being implemented in a real-world application aimed at automating crop monitoring. In this way, the adoption of artificial intelligence in agribusiness can contribute to more sustainable and productive agriculture, benefiting both farmers and society at large.

**Keywords:** Agribusiness, Artificial Intelligence, Technology, Asian Soybean Rust.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Diagrama dos tipos de aprendizado em machine learning.....	18
Figura 2 – Diagrama de aprendizado supervisionado.....	19
Figura 3 – Diagrama de funcionamento de aprendizado não supervisionado.....	20
Figura 4 – Diagrama de aprendizado por reforço.....	21
Figura 5 – Diagrama de funcionamento de uma rede neural convolucional genérica.....	22
Figura 6 – A arquitetura geral da Rede Neural Convolucional (CNN).....	24
Figura 7 – Demonstração dos Alfes do projeto.....	27
Figura 8 – Demonstração das Práticas do projeto.....	29
Figura 9 – Demonstração das Competências do projeto.....	31
Figura 10: Imagem de folha de soja infectada por ferrugem asiática.....	33
Figura 11 – Imagem de folha de soja saudável.....	34
Figura 12 – Visão geral da arquitetura do algoritmo ResNetv50.....	35
Figura 13 – Visão geral do ViT-1.58b.....	36
Figura 14 – Curva de ROC ResNet.....	42
Figura 15 – Matriz de Confusão ResNet.....	43
Figura 16 – Curva de ROC do Vision Transformers.....	47
Figura 17 – Matriz de Confusão do Vision Transformers.....	48
Figura 18 – Aplicação do algoritmo Vision Transformers: escolha de imagem.....	51
Figura 19 – Aplicação do algoritmo Vision Transformers: classificação da folha de soja.....	52
Figura 20 – Aplicação do algoritmo Vision Transformers: classificação da folha de soja em campo...	53
Figura 21 – Aplicação do algoritmo Vision Transformers: classificação da folha de soja em campo...	54

## LISTA DE ABREVIATURAS

AUC - *Area Under the Curve* (Área Sob a Curva)

CNN - *Convolutional Neural Network* (Rede Neural Convolucional)

GAN - *Generative Adversarial Network* (Rede Adversária Generativa)

IA - Inteligência Artificial

IoT - *Internet of Things* (Internet das Coisas)

KNN - *K-Nearest Neighbors*

L2 - Regularização L2

ReLU - *Rectified Linear Unit*

RNN - *Recurrent Neural Network* (Rede Neural Recorrente)

ROC - *Receiver Operating Characteristic*

SVM - *Support Vector Machine*

ViT - *Vision Transformers*

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>11</b>
1.1 JUSTIFICATIVA.....	12
1.2 OBJETIVOS.....	12
1.2.1 Objetivos Gerais.....	13
1.2.2 Objetivos Específicos.....	13
1.3 ESTRUTURA DO TEXTO.....	13
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>14</b>
2.1 AGRONEGÓCIO BRASILEIRO.....	14
2.2 TECNOLOGIA NO SETOR AGRÍCOLA.....	15
2.3 INTELIGÊNCIA ARTIFICIAL NO CAMPO.....	16
2.4 MACHINE LEARNING.....	17
2.4.1 Aprendizado supervisionado.....	18
2.4.2 Aprendizado não supervisionado.....	19
2.4.3 Aprendizado por reforço.....	20
2.5 DEEP LEARNING.....	21
2.6 ALGORITMOS E TECNOLOGIAS DE VISÃO COMPUTACIONAL.....	23
<b>3 METODOLOGIA.....</b>	<b>26</b>
3.1 ALFAS.....	26
3.2 PRÁTICAS.....	28
3.3 COMPETÊNCIAS.....	30
<b>4 ALGORITMOS DE MACHINE LEARNING PARA DETECÇÃO DE DOENÇAS... 32</b>	<b>32</b>
4.1 COLETA DE DADOS.....	32
4.2 ESCOLHA DOS ALGORITMOS.....	34
4.2.1 ResNetv50.....	35
4.2.2 Vision Transformers.....	36
<b>5 RESULTADOS.....</b>	<b>38</b>
5.1 RESNETV50.....	38
5.2 VISION TRANSFORMERS.....	45
5.3 DISCUSSÃO.....	48
5.4 IMPLEMENTAÇÃO.....	50
<b>6 CONSIDERAÇÕES FINAIS.....</b>	<b>56</b>
<b>REFERÊNCIAS.....</b>	<b>58</b>

## 1 INTRODUÇÃO

O agronegócio brasileiro tem sido um setor em constante transformação, apresentando crescimento significativo tanto em expansão comercial quanto em inovações tecnológicas. Segundo dados do Cepea/Esalq/USP-CNA (2024), o PIB do agronegócio brasileiro foi de R\$ 2,45 trilhões no primeiro trimestre de 2024, com R\$ 1,65 trilhão no ramo agrícola e R\$ 801 bilhões no ramo pecuário. Essa transformação vem promovendo avanços notáveis em termos de eficiência operacional e sustentabilidade ambiental.

Neste cenário promissor, tecnologias emergentes como a Inteligência Artificial (IA) e a Internet das Coisas (IoT) destacam-se como ferramentas estratégicas para impulsionar ainda mais o crescimento do setor agropecuário. Com cada avanço, essas inovações transformam o panorama do agronegócio, trazendo perspectivas e oportunidades antes inimagináveis. Essas tecnologias são amplamente incorporadas no setor por meio da Agricultura 4.0 e 5.0, que, segundo Borem (2021), fazem uso de rede de sensores, computadores, *smartphones* e comunicação entre máquinas, IA, *Big Data* e computação na nuvem. Essas ferramentas auxiliam na tomada de decisões, promovendo a redução de custos e permitindo a formulação de estratégias mais eficazes diante de cenários desafiadores, como variações climáticas extremas e a evolução constante de patógenos, microorganismos causadores de doenças em plantas e animais.

No combate aos patógenos que ameaçam as culturas agrícolas, a IA emerge como ferramenta valiosa na prevenção e detecção de doenças nas lavouras. Por meio de mapas topográficos e imagens aéreas captadas por drones, a IA analisa dados de maneira precisa, permitindo aplicações defensivas mais assertivas e preventivas (Piccolo, 2024). Um exemplo notável é o uso de algoritmos de IA treinados com conjuntos de imagens de folhas de soja, que classificam e diferenciam folhas saudáveis de aquelas que apresentam sinais de doenças (Tabosa, Oliveira, Hayama, 2024).

Entre as doenças detectadas por IA está a ferrugem asiática, causada pelo fungo *Phakopsora pachyrhizi*. A Ferrugem é caracterizada por pequenas lesões de coloração marrom ou marrom-clara na superfície das folhas, comprometendo a fotossíntese e reduzindo significativamente a produtividade das plantas (Hartman, 2015).

A detecção precoce de doenças agrícolas é de extrema importância, pois permite uma intervenção rápida e eficaz. Isso não apenas reduz a dependência de defensivos agrícolas, mas também diminui os danos às colheitas e melhora a produtividade geral (Embrapa, 2008). Uma

intervenção precisa e oportuna pode fazer a diferença entre a prevenção de uma epidemia e a perda significativa de rendimento.

## 1.1 JUSTIFICATIVA

Em um mercado tão competitivo como o agronegócio é fundamental proporcionar novas tecnologias ao setor do agronegócio de forma que ela apoie o produtor das mais diferentes formas, na seleção de grãos e mudas, na aplicação de defensivos. O uso de IA no agronegócio acarreta benefícios não só para o produtor, mas também para o meio ambiente, por meio de uma aplicação mais precisa de defensivos agrícolas vindo como uma tecnologia para auxiliar na agricultura de precisão. Segundo Zhang (2016), a tecnologia de agricultura de precisão permite otimizar o uso de recursos e aumentar a produtividade das culturas.

Com base em um algoritmo treinado sobre uma base de dados abrangente, é possível alcançar um desempenho de sucesso que realmente forneça benefícios visíveis para o produtor. A capacidade de detectar e prevenir doenças de forma eficaz minimiza o uso de insumos químicos, reduzindo o impacto ambiental e promovendo práticas agrícolas mais sustentáveis. Tao et al. (2023) destacam que a IA pode transformar os sistemas agroalimentares modernos, contribuindo para práticas agrícolas mais sustentáveis e economicamente viáveis.

O presente estudo justifica-se pela necessidade de integrar tecnologias de reconhecimento utilizando algoritmos de IA no setor agrícola, promovendo uma agricultura mais inteligente e eficiente. Ao fornecer ferramentas de precisão para o manejo de culturas, podemos melhorar a produtividade, reduzir custos e criar um impacto positivo tanto econômico quanto ecológico. O uso de IA no agronegócio acarreta benefícios não só para o produtor, mas também para o meio ambiente, por meio de uma aplicação mais precisa de defensivos agrícolas, alinhadas com alguns dos Objetivos de Desenvolvimento Sustentável (ODS) estabelecidos pela ONU como o consumo e produção responsáveis.

## 1.2 OBJETIVOS

O presente trabalho tem como objetivo analisar e testar algoritmos de bibliotecas de IA para identificar aqueles com melhor aplicação na detecção e prevenção da ferrugem asiática – uma das doenças mais prejudiciais à cultura da soja – utilizando a análise de imagens de folhas. Este estudo busca otimizar o uso de defensivos agrícolas, promovendo

uma agricultura mais sustentável e eficiente, e proporcionando benefícios econômicos e ambientais ao produtor ao oferecer ferramentas tecnológicas para o monitoramento e controle proativo da doença.

### 1.2.1 Objetivos Gerais

Projetar e validar uma solução utilizando IA para identificação de folhas de soja afetadas pela ferrugem asiática, para auxiliar o produtor no dia a dia do campo, permitindo uma tomada de decisão mais assertiva e eficiente na aplicação de defensivos agrícolas.

### 1.2.2 Objetivos Específicos

- Analisar as características das imagens de folhas de soja afetadas e não afetadas pela ferrugem asiática, garantindo que os dados coletados sejam adequados para o treinamento de modelos de inteligência artificial.
- Definir os requisitos fundamentais para que a IA seja eficaz na detecção precoce de doenças na soja, incluindo a qualidade, variabilidade e representatividade dos dados utilizados.
- Avaliar se a solução implementada atende aos critérios estabelecidos e oferece suporte efetivo ao produtor na identificação e monitoramento de doenças nas folhas de soja, promovendo sua aplicação prática e eficácia no campo.

## 1.3 ESTRUTURA DO TEXTO

O trabalho está estruturado em seis capítulos. A seguir, o Capítulo 2 discute os conceitos-chave que sustentam a pesquisa, como o uso de *machine learning* e *deep learning* no setor agrícola, detalhando os principais algoritmos empregados na análise de imagens. O Capítulo descreve os procedimentos adotados para a realização do estudo, incluindo a coleta de dados, os critérios de seleção dos algoritmos e os métodos de validação. O Capítulo 4 apresenta a parte inicial de como foi feita a coleta e separação dos dados e como foi feita a escolha inicial dos algoritmos e as suas distinções em termos de processamento de imagens. O Capítulo 5 analisa os resultados obtidos e compara o desempenho dos modelos *ResNet* e *Vision Transformers* na detecção de doenças em folhas de soja. Por fim, O Capítulo 6 sintetiza os principais achados, aponta limitações do estudo e sugere direções para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Esta seção aborda os conceitos que sustentam o desenvolvimento deste trabalho. Na Seção 2.1, são discutidas as características do agronegócio brasileiro e seu contexto de inovação tecnológica. A Seção 2.2 explora o papel da tecnologia no setor agrícola, enquanto a Seção 2.3 discorre sobre a aplicação da IA no campo. Na Seção 2.4 são apresentadas as diferentes abordagens de aprendizado de máquina, fundamentais para a análise de imagens de folhas de soja. Em complemento, a Seção 2.5 foca-se em redes neurais e aprendizado profundo, enquanto a Seção 2.6 aborda a área de visão computacional.

### 2.1 AGRONEGÓCIO BRASILEIRO

O agronegócio brasileiro vem se tornando uma força essencial para o Brasil e o setor mundial. Com vastas áreas cultiváveis, o Brasil se destaca como um dos grandes exportadores de alimentos do mundo (Herbert, 2020). No entanto, o sucesso do setor não se deve apenas à sua extensa área produtiva, mas também está aliado a diversas evoluções industriais, tecnológicas e a programas de incentivo ao produtor rural. O Brasil deixou de ser um importador de alimentos para se tornar um grande provedor para o mundo (Embrapa, 2018). Segundo o Ministério da Agricultura e Pecuária (2024), as exportações brasileiras do agronegócio atingiram mais de US\$ 15 bilhões em maio de 2024, representando 49,6% das exportações totais do Brasil.

No cenário internacional, o Brasil se destaca como um dos maiores fornecedores de carnes e cereais. A crescente demanda por alimentos de alta qualidade, tanto no mercado interno quanto externo, tem incentivado o setor a investir continuamente em melhorias, desde a modernização de maquinários agrícolas até o desenvolvimento de insumos mais eficientes e sustentáveis (Ramos, 2017).

Entretanto, mesmo com o avanço das tecnologias, o Brasil ainda enfrenta desafios clássicos, como doenças agrícolas. Problemas como a ferrugem, abordadas neste trabalho, continuam a afetar os produtores rurais. A ferrugem apresenta um ciclo de vida que se caracteriza por um padrão policíclico, favorecendo sua rápida disseminação e severidade nas lavouras. O fungo sobrevive em plantas hospedeiras e resíduos culturais, liberando esporos (urediniósporos) que são transportados pelo vento para infectar plantas suscetíveis. As condições climáticas, como alta umidade relativa e temperaturas amenas (entre 18°C e 26°C), favorecem a germinação dos esporos e a penetração direta do fungo nos tecidos da planta.

Uma vez estabelecido, o fungo forma estruturas de reprodução, como urédias, nas folhas, liberando novos esporos e perpetuando o ciclo. O processo de infecção até a esporulação pode ocorrer em um curto intervalo de 7 a 10 dias, contribuindo para epidemias rápidas.

A detecção precoce da ferrugem asiática é essencial para evitar perdas significativas na produção e possibilitar o manejo eficaz da doença (Almeida, 2005). Métodos de monitoramento visual, com observação das primeiras lesões em folhas mais baixas, são frequentemente utilizados, mas podem ser complementados por ferramentas tecnológicas. Ensaio moleculares, como a reação em cadeia da polimerase (PCR), permitem a identificação do patógeno antes mesmo do aparecimento de sintomas visíveis. Além disso, sistemas de alerta baseados em modelos climáticos e sensores remotos têm sido desenvolvidos para prever o risco de infecção, otimizando a aplicação de fungicidas preventivos e garantindo maior sustentabilidade no manejo integrado da doença.

Com isso o Brasil acabou se tornando um destino para investimentos no setor agrícola para testar novas técnicas de combate a essas doenças e diversas outras. Empresas nacionais e internacionais veem no país um mercado promissor, onde as oportunidades de crescimento são vastas e o potencial para inovação é enorme (Ministério da Agricultura e Pecuária, 2023).

## 2.2 TECNOLOGIA NO SETOR AGRÍCOLA

A tecnologia tem sido presente em diversos setores, seu impacto tem sido cada vez mais evidente no dia a dia das pessoas. Nicholas Carr (2011) diz que, toda vez que uma tecnologia chegar em nossas vidas, nós não seremos mais os mesmos. No setor agrícola brasileiro não foi diferente, essa revolução tecnológica tem desempenhado um papel ainda mais crucial, transformando como a agricultura é praticada e gerida (Klerkx, 2019).

A inserção de tecnologia nos maquinários agrícolas trouxe eficiência e precisão para os produtores rurais, segundo dados da Federação da Agricultura e Pecuária do Mato Grosso do Sul (Famasul, 2021), o produtor de pequeno, médio ou grande porte que investe em agricultura de precisão aumenta a produtividade em até 29%. Equipamentos modernos agora possuem sensores que permitem a detecção precoce de problemas mecânicos, minimizando o tempo de inatividade e reduzindo custos.

Mudanças vêm sendo feitas não apenas em maquinários, mas nas sementes e insumos a serem utilizados a evolução da biotecnologia permitiu o surgimento de sementes geneticamente modificadas que são mais resistentes a condições adversas, como seca e

pragas, além de defensivos agrícolas que oferecem maior proteção contra doenças e pragas (Ivan, 2023). Além dos maquinários e insumos, a digitalização do campo está trazendo novas possibilidades para os produtores. *Softwares* de gestão agrícola permitem a análise detalhada de dados sobre solo, clima e produtividade, ajudando os agricultores a tomar decisões mais informadas (Massruhá, 2020). Essas ferramentas possibilitam o planejamento estratégico, que leva em consideração as variáveis ambientais e econômicas, resultando em uma gestão mais eficaz e lucrativa, assim modificando o setor agrícola brasileiro. O que antes dependia quase exclusivamente da experiência e do trabalho manual, agora é auxiliado por ferramentas e sistemas que os produtores utilizam no seu dia a dia.

Embora as inovações tecnológicas estejam cada vez mais presentes no campo, ainda existem desafios para sua adoção ampla, especialmente entre pequenos e médios produtores. É importante destacar que, naturalmente, quanto maior a plantação, maior o acesso às tecnologias avançadas. Grandes produtores têm mais facilidade em adquirir e implementar tecnologias, enquanto pequenos e médios produtores enfrentam barreiras que dificultam a adoção dessas inovações (Buainain, 2021). Esse cenário traz a necessidade de desenvolver soluções tecnológicas mais inclusivas, que possibilitem o acesso facilitado a novas inovações. Entre essas soluções, destaca-se a IA, que tem o potencial de impulsionar ainda mais a agricultura. Uma forma eficiente de utilizar a IA no campo é na análise de dados ao longo das safras, desde as preparações do solo até as etapas de pós-colheita.

### 2.3 INTELIGÊNCIA ARTIFICIAL NO CAMPO

A inteligência artificial (IA) está transformando a agricultura ao integrar tecnologias que não apenas aumentam a produtividade, mas também a sustentabilidade. Sua aplicação é ampla, abrangendo desde softwares de gestão até maquinários agrícolas, que utilizam sistemas inteligentes para facilitar a vida do produtor (Gatkal et al., 2024).

Não só sendo utilizado em maquinários de grande porte, mas em coisas mais simples como uma horta, onde o uso de sensores de umidade do solo e sistemas de irrigação baseados em IA pode reduzir o consumo de água e facilitar o monitoramento completo de todas as métricas na estufa ou campo, como temperatura, umidade e nutrientes no solo (Obaideen, 2022). Além disso, a implementação de drones agrícolas equipados com IA para o monitoramento de cultivos tem se mostrado eficaz na detecção precoce de pragas e doenças e aplicação localizada de pesticidas que ajudam o produtor em aplicações localizadas e facilitem o manejo dele em diferentes culturas (Hafeez et al., 2023).

Desempenhando um papel crucial na prevenção de doenças e na aplicação otimizada de defensivos agrícolas, que contribui para processos mais sustentáveis e com menor impacto ambiental, resultando em ganhos significativos de produtividade (Rajagopal, 2023). Esses avanços não só resultam em maior eficiência, mas também em uma significativa redução do impacto ambiental, tornando os processos agrícolas mais ecoeficientes e alinhados com as práticas de agricultura sustentável. Essas inovações são valiosas para os agricultores que podem se basear em outras ferramentas de trabalho além das utilizadas convencionalmente, como apoio de engenheiros agrônomos e conhecimentos passados de geração para geração.

Para realizar essa implementação de IA no campo, pode-se buscar modelos baseados em redes neurais que buscam imitar a inteligência humana de diversas formas, uma delas é fazendo essas análises descritas e evitando às vezes pontos que poderiam ser ignorados ou não calculados por uma pessoa normal. Segundo Sage (1990), a IA tem por objetivo desenvolver paradigmas ou algoritmos que necessitam de máquinas para realizar tarefas. Hoje a IA tem capacidade de realizar diversas tarefas desde coisas extremamente simples até algo complexo como uma releitura filosófica, isso mostra como ela tem evoluído cada vez mais e vai evoluir auxiliando o ser humano no seu dia-a-dia, mas o que ela não deve substituir as características genuinamente humanas.

Dentro do campo da IA, destacam-se subáreas como o *machine learning* (aprendizado de máquina) e o *deep learning* (aprendizado profundo) (Domingos, 2015; Good-Dfelow; Bengio; Courville, 2016; Alpaydin, 2016). Ambas são utilizadas em tarefas específicas, onde oferecem um desempenho superior, mostrando o potencial de cada tecnologia em auxiliar o ser humano em tarefas diárias, desde decisões agrícolas até processos mais complexos.

## 2.4 MACHINE LEARNING

Dentro do campo da IA, o *machine learning* destaca-se pela capacidade das máquinas de aprenderem a partir de dados, segundo a definição de Samuel (1959), um dos pioneiros do assunto, o aprendizado de máquina é “um campo de estudo que oferece aos computadores a capacidade de aprender sem serem explicitamente programados”. Essa tecnologia permite que os algoritmos analisem grandes volumes de dados, identifiquem padrões e façam previsões de forma autônoma, aprimorando continuamente seus resultados por meio de autotreinamento.

Para realizar o autoaprendizado, utiliza-se de diferentes abordagens, como aprendizado supervisionado, não supervisionado e por reforço. Cada uma dessas abordagens possui características específicas que determinam como o aprendizado é realizado e em quais

situações são mais adequadas para serem aplicadas. A Figura 1 ilustra essas abordagens, destacando suas aplicações, como análise de dados rotulados, identificação de padrões e adaptação a interações no ambiente.

A Figura 1 sintetiza como cada técnica é aplicada em problemas distintos, como classificação, regressão e análise de padrões complexos. Ele também ajuda a compreender a adaptação de algoritmos a diferentes situações, oferecendo uma visão prática das possibilidades no aprendizado de máquina.



Figura 1 – Diagrama dos tipos de aprendizado em *machine learning*.

Fonte: DataAt (2020).

#### 2.4.1 Aprendizado supervisionado

O aprendizado supervisionado recebe um conjunto de entradas com suas respectivas saídas e busca encontrar uma função que estabeleça uma relação aproximada entre elas. O objetivo é fazer com que o modelo consiga prever a saída correta para novas entradas que ainda não foram vistas durante o treinamento (Russel; Norvig, 2002). A Figura 2 ilustra o funcionamento básico de um modelo de aprendizado supervisionado, onde os dados de entrada (*labels*) são processados pelo modelo para gerar as saídas previstas (*predictions*). O processo envolve a comparação das saídas geradas com as saídas reais.




Figura 2 – Diagrama de aprendizado supervisionado.

Fonte: Enjoy Algorithms (2023).

No diagrama, é possível observar como o processo ocorre. Os dados rotulados (dados de entrada com seus rótulos) são alimentados ao modelo de aprendizado de máquina, que aprende a classificar ou prever a categoria correta para novos dados. Esse fluxo ilustra como o aprendizado supervisionado permite a criação de modelos que, uma vez treinados, podem generalizar seu conhecimento para novos dados.

#### 2.4.2 Aprendizado não supervisionado

O aprendizado não supervisionado é um tipo de algoritmo que trabalha com dados não rotulados, ou seja, sem categorias ou classificações pré-definidas. O objetivo do algoritmo é identificar padrões ocultos ou agrupar os dados com base em suas semelhanças, sem uma indicação explícita do que deve ser encontrado (Russel; Norvig, 2002). A Figura 3 apresenta o funcionamento de um modelo de aprendizado não supervisionado, mostrando como ele processa as entradas sem a necessidade de rótulos pré-definidos, identificando padrões e estruturas ocultas nos dados.

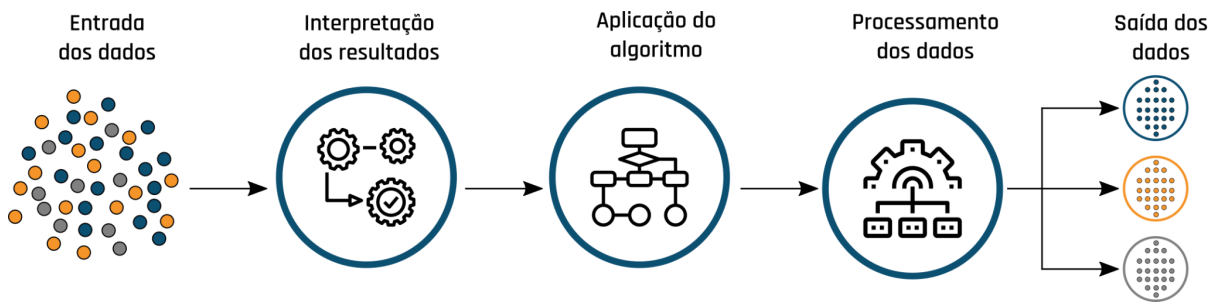


Figura 3 – Diagrama de funcionamento de aprendizado não supervisionado.

Fonte: DataAt (2020).

Com base na estrutura dos dados totalmente confusa, o modelo organiza e classifica automaticamente os dados, detectando relações ou agrupamentos que podem não ser aparentes à primeira vista. Esse processo é amplamente utilizado em aplicações como análise de *clusters*, detecção de anomalias e segmentação de dados, demonstrando seu potencial em diversas áreas de pesquisa e prática.

#### 2.4.3 Aprendizado por reforço

O aprendizado por reforço é um método baseado em tentativa e erro, onde o algoritmo aprende a tomar decisões a partir de atividades com o ambiente. A cada ação tomada, ele recebe uma recompensa ou punição, dependendo do resultado. Com o tempo, o algoritmo ajusta suas ações, buscando obter mais recompensas e minimizar os erros, evoluindo até encontrar uma solução otimizada para o problema. O objetivo é aprender a escolher ações que tenham os melhores resultados possíveis, com base em experiências anteriores (Sutton, 1998). A Figura 4 retrata o funcionamento do aprendizado por reforço, onde um agente aprende a tomar decisões interagindo com o ambiente. Ele recebe recompensas ou penalidades com base nas ações executadas, ajustando seu comportamento ao longo do tempo para maximizar as recompensas acumuladas.

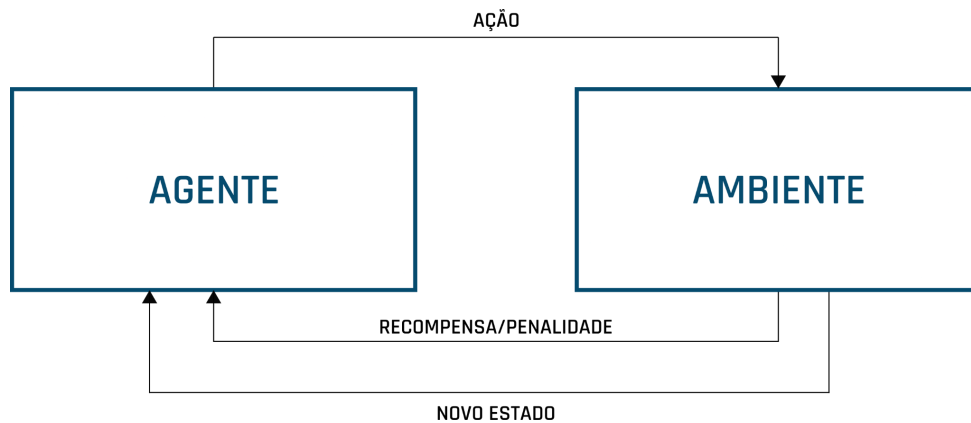


Figura 4 – Diagrama de aprendizado por reforço.

Fonte: DataAt (2020).

Esse é um ciclo que define o aprendizado por reforço, a ação é executada no ambiente e existe a validação do agente dizendo se a decisão tomada foi ou não correta. No campo, o *machine learning* pode ser utilizado para processar grandes quantidades de dados gerados por sensores, drones, satélites e outros dispositivos.

## 2.5 DEEP LEARNING

O *deep learning* se caracteriza por ser um modo de raciocínio que processa através de redes neurais artificiais com várias camadas, imitando a estrutura e a função do cérebro humano. Amplamente utilizado em tarefas específicas, como reconhecer imagens, traduzir idiomas entre outras tarefas (Goodfellow; Bengio; Courville, 2016).

A rede neural se caracteriza por ser um sistema de neurônios artificiais, às vezes chamados de perceptrons, que são como nós computacionais usados para classificar e analisar dados. A Figura 5 demonstra o funcionamento básico de uma rede neural genérica.




Figura 5 – Diagrama de funcionamento de uma rede neural convolucional genérica.

Fonte: Opencadd (2022).

Como apresentado na Figura 5 os dados são alimentados na primeira camada, em que cada percepção recebe uma decisão e, em seguida, transmite essas informações para vários nós na próxima camada. Os modelos de treinamento com mais de três camadas são chamados de “redes neurais profundas” ou “aprendizado profundo”. Algumas redes neurais modernas têm centenas ou milhares de camadas. A saída final dos preceptores realiza a tarefa definida para a rede neural, como classificar um objeto ou encontrar padrões nos dados fornecidos.

Para realizar essas tarefas são utilizados alguns algoritmos como redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs) e redes generativas adversárias (GANs). As CNNs (LeCun, 1998) são particularmente eficazes na análise de imagens. Por exemplo, imagens capturadas por drones ou câmeras no campo podem ser analisadas para identificar sinais iniciais de ferrugem asiática, como pequenas manchas nas folhas, que seriam imperceptíveis a olho nu em grandes áreas. Modelos como ResNet ou Inception têm sido amplamente utilizados para esse fim, atingindo altas taxas de acurácia na classificação de doenças em estudos recentes (FERREIRA et al., 2021). As RNNs (Elman, 1990), por sua vez, são ideais para analisar séries temporais de dados, ajudando a prever tendências climáticas que podem afetar as colheitas. Já as GANs (Goodfellow, 2014) podem ser usadas para gerar simulações de possíveis cenários agrícolas, auxiliando na tomada de decisões estratégicas.

Quando testados e aprovados em situações reais, esses algoritmos demonstram sua eficácia, facilitando a detecção precoce de problemas e proporcionando uma base mais assertiva para decisões agrícolas em meio a condições adversas (Tabosa, Oliveira, Hayama,

2024). O uso de IA em exemplos como os discutidos em (Piccolo, 2024) exemplifica o potencial transformador dessa tecnologia no campo.

Esses algoritmos podem ser implantados em softwares específicos que atuam como ferramentas auxiliares para os produtores, permitindo que, por exemplo, uma imagem capturada por um drone seja analisada para detectar precocemente doenças como a ferrugem asiática. Dessa forma, os produtores podem ser alertados com antecedência, permitindo que tomem medidas preventivas mais eficazes e direcionadas, resultando em uma gestão agrícola mais eficiente e sustentável.

## 2.6 ALGORITMOS E TECNOLOGIAS DE VISÃO COMPUTACIONAL

Existem diversos modelos e abordagens para analisar uma imagem, sendo os algoritmos de classificação um dos métodos mais comuns (Goodfellow.; Bengio; Courville, 2016). Esses algoritmos têm como objetivo principal separar elementos distintos ou agrupar itens semelhantes, estabelecendo, por exemplo, que “A” é diferente de “B”. Dessa forma, a classificação permite identificar padrões e categorias dentro de um conjunto de dados, facilitando a distinção entre diferentes classes de objetos ou características.

Outro método comum é o de regressão, que não foca em classificar ou categorizar os dados, mas sim em realizar previsões com base em valores iniciais. Em vez de separar os dados em classes, o modelo de regressão prevê um valor contínuo. Por exemplo, você pode apresentar alguns produtos e seus preços para que o algoritmo construa o modelo. Ainda que não haja nenhum produto com preço superior a R\$100,00, o modelo poderá realizar previsões de preços acima desse valor, utilizando padrões e tendências aprendidos nos dados fornecidos.

Alguns algoritmos que têm uma boa performance em relação à análise de imagens que trabalham em cima de um modelo de CNNs (LeCun 1998). As CNNs são especialmente poderosas em tarefas que envolvem reconhecimento e classificação de imagens, devido à sua capacidade de capturar e interpretar padrões visuais complexos em diferentes níveis, desde bordas simples até características mais detalhadas.

As CNNs são modelos de classificação que funcionam por meio de camadas convolucionais que filtram a imagem de entrada, identificando características visuais em diferentes escalas (Alom et al., 2019). Isso as torna ideais para diversas aplicações, como detecção de objetos, segmentação de imagens e diagnóstico médico baseado em imagens. A Figura 6 demonstra o funcionamento de uma CNN. Ela utiliza camadas convolucionais para extrair características relevantes dos dados de entrada, como imagens, aplicando filtros que

detectam padrões, como bordas e texturas, para posteriormente realizar tarefas como classificação ou detecção de objetos.

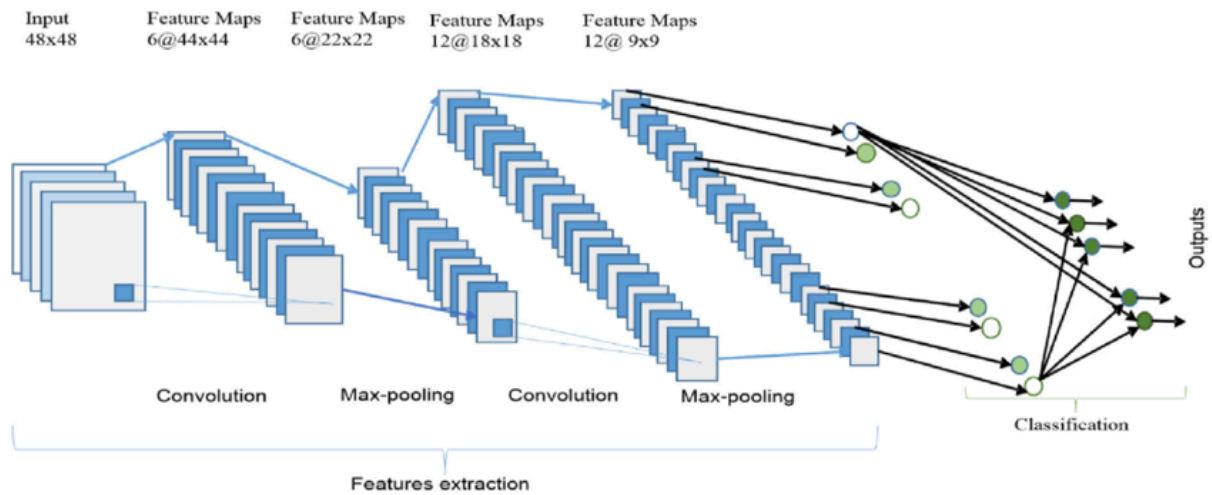


Figura 6 – A arquitetura geral da Rede Neural Convolucional (CNN).

Fonte: Alom et al. (2019).

Basicamente, as camadas da CNN são organizadas em grades 2D ou 3D que chamamos de filtros. Cada filtro extrai os diferentes tipos de recursos dos dados de entrada. Um filtro pode extrair arestas, linhas, círculos ou formas mais complexas (LeCun, 1998). As CNN consistem em camadas de nós (ou neurônios) interconectados, elas trabalham de forma semelhante ao cérebro humano, utilizando processos que imitam a maneira como os neurônios trabalham juntos para identificar fenômenos, avaliar opções e chegar a conclusões (Thakur; Konde, 2021). Esses modelos conseguem aprender representações complexas dos dados e podem capturar padrões não lineares, tornando-os eficazes em tarefas como reconhecimento de imagem, processamento de linguagem natural e muito mais.

Um modelo de classificação é o *Support Vector Machine* (SVM), que busca encontrar uma linha de separação entre duas classes distintas, analisando os pontos mais próximos de cada classe. Em termos mais técnicos, essa linha é chamada de hiperplano quando se lida com dados em mais de duas dimensões. O objetivo do SVM é maximizar a margem entre as classes, isto é, a distância entre o hiperplano e os pontos de dados mais próximos de cada classe, conhecidos como vetores de suporte (IBM, 2024).

Outro modelo de classificação é o *K-nearest neighbors* (KNN), que atribui uma classe a um novo dado com base nos “K” vizinhos mais próximos. O algoritmo identifica os dados mais próximos no espaço de características e verifica a classe predominante entre eles. Assim, ele classifica o novo dado de acordo com seus vizinhos mais semelhantes, atribuindo-lhe a mesma categoria ou realizando previsões baseadas nesses padrões (Guo; Wang; Bell, 2003).

Recentemente e mais focado para análise de imagens e muito utilizado é os *Vision Transformers* (ViTs). Essa técnica aplica a arquitetura dos *Transformers* ao processamento de imagens, dividindo a imagem em pequenos blocos, chamados de patches. Esses patches são tratados como sequências de entrada, semelhante ao processamento de texto em *Natural Language Processing* (NLP). Essa estratégia, que segue o princípio de “dividir para conquistar”, permite uma análise mais detalhada e eficiente das imagens (Park, 2022).

Modelos como SVM, VITS e as CNNs oferecem boas abordagens para a análise de imagens, cada um com suas vantagens e desvantagens. Enquanto o SVM pode ser eficaz em tarefas com menos complexidade e dados bem definidos, as redes neurais e os ViTs geralmente demandam mais processamento de GPU e são mais adequados para bases de dados maiores e mais complexas. Dentre os modelos mais avançados atualmente, os ViTs têm se destacado pela sua capacidade de lidar com grandes volumes de dados e fornecer análises detalhadas, superando muitas vezes outras abordagens em termos de performance e precisão (Sinha, 2023).

Essas são uma das principais técnicas e algoritmos de visão computacional utilizados na análise de imagens, como as CNNs, SVM e *Vision Transformers*, trazendo suas capacidades e limitações. No contexto deste trabalho, essas abordagens foram consideradas na construção da metodologia adotada, detalhada na próxima seção, que descreve os processos de seleção, aplicação e avaliação dos modelos para a detecção de doenças em folhas de soja.

### 3 METODOLOGIA

A metodologia abordada neste estudo é a Essence (OMG, 2024), um *framework* projetado para auxiliar equipes de qualquer tamanho, desde pequenas a grandes, no desenvolvimento de *software*. O Essence oferece uma abordagem ampla e flexível, tratando de aspectos essenciais para empreendimentos de engenharia de *software*, como requisitos, sistemas, equipes e atividades (OMG, 2024).

O *framework* é estruturado em três componentes principais: Alfas, Práticas e Competências. Alfas são elementos fundamentais que representam o progresso do projeto. Práticas são maneiras de lidar com problemas comuns no desenvolvimento de *software*, como gerenciamento de riscos e planejamento. As competências referem-se às habilidades e conhecimentos necessários para executar as tarefas, como liderança, colaboração e habilidades técnicas. Esses componentes ajudam a gerenciar o tempo e os recursos de forma eficaz, além de oferecer controle sobre os processos. Com isso, o Essence facilita a organização e execução dos projetos.

#### 3.1 ALFAS

Os Alfas consistem em metas a serem alcançadas durante o desenvolvimento, funcionando como um guia desde o levantamento de requisitos até a fase final de implementação e melhoria contínua, garantindo a boa manutenção do *software*. Cada Alfa aborda aspectos essenciais do projeto. Na Essence, os Alfas são semelhantes às fases do *Waterfall* no sentido de que servem como marcos a serem atingidos em cada etapa do projeto. Ao contrário do *Waterfall*, onde a passagem de uma fase para outra é rígida e sequencial, os Alfas da Essence oferecem maior flexibilidade (OMG, 2024).

Por exemplo, na área de solução, a equipe precisa estabelecer uma compreensão comum dos requisitos e implementar, construir, testar, implantar e apoiar um sistema que satisfaçam alguns pontos como:

- Requisitos: As quais são o que o sistema deve fazer para atender à oportunidade e satisfazer as partes interessadas. É importante descobrir as necessidades do sistema, compartilhar essa compreensão entre os stakeholders e membros da equipe, e usá-la para guiar o desenvolvimento e os testes do novo sistema.

- Sistema: Consiste em um conjunto de elementos que interagem para atingir um propósito definido. Esses elementos podem incluir hardware, *software*, dados, humanos, processos, serviços, procedimentos, instalações, materiais e entidades naturais.

Seguindo os princípios estabelecidos pela Essence, os Alfas devem abordar elementos fundamentais do projeto, como os requisitos do sistema, conforme demonstrado na Figura 7. Esses elementos incluem os objetivos principais do projeto, como a escolha e a implementação de algoritmos adequados para o produtor.

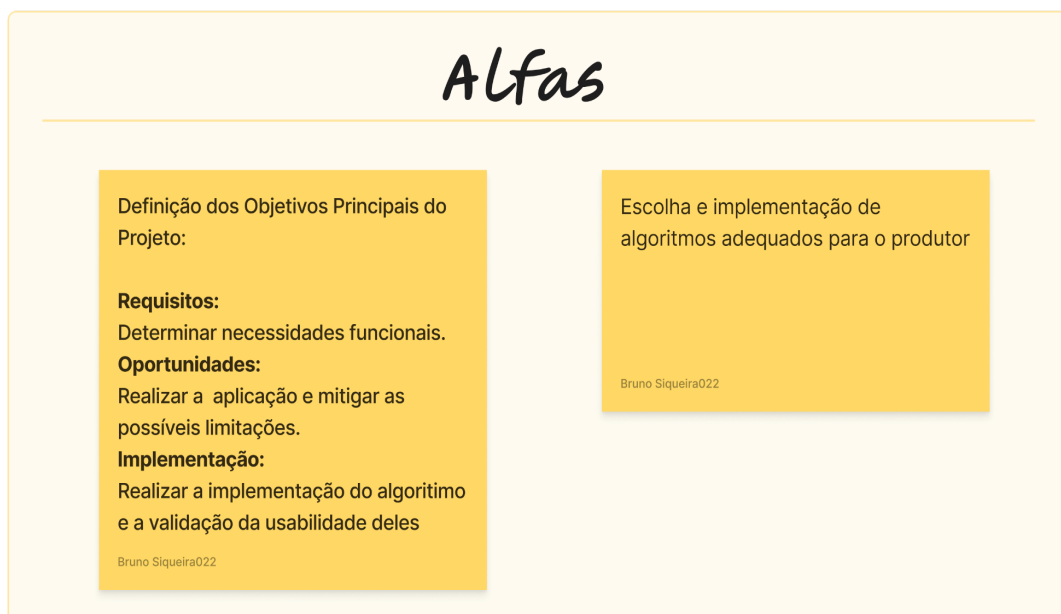


Figura 7 – Demonstração dos Alfas do projeto.

Fonte: Elaborado pelo autor.

Conforme ilustrado na Figura 7, os Alfas do projeto abrangem três pilares principais. O primeiro, “requisitos”, envolve a identificação e definição das necessidades funcionais para a implementação dos algoritmos. Isso inclui aspectos como o processamento gráfico necessário, a memória da máquina onde o algoritmo será treinado e validado, entre outros recursos fundamentais. Para atender a esses requisitos, optou-se pelo uso do *Google Colab*, uma plataforma que oferece suporte adequado para a execução desses processos e, ao mesmo tempo, é de fácil acesso e gratuita, facilitando a implementação e o desenvolvimento do modelo sem a necessidade de infraestrutura especializada.

O segundo, “oportunidades”, refere-se à aplicação prática dos algoritmos, incluindo sua usabilidade na detecção de doenças em lavouras de soja por meio da análise de imagens de folhas. Ou seja, trata-se da oportunidade que o produtor tem de adotar uma solução tecnológica que facilite o seu dia a dia, otimizando o monitoramento das lavouras e a tomada de decisões. Além disso, também envolve a oportunidade de desenvolvimento da solução, inserindo-a em um mercado de crescimento exponencial, onde a IA e outras tecnologias inovadoras têm o potencial de transformar o agronegócio.

Por fim, o terceiro pilar, “implementação”, concentra-se na aplicação prática dos algoritmos selecionados, seguida de sua validação para assegurar que atendem às necessidades e oportunidades previamente identificadas. Esse pilar também envolve a validação contínua da solução, assegurando que os algoritmos não só sejam eficazes, mas também possam ser integrados de forma funcional e escalável no contexto real do produtor rural.

### 3.2 PRÁTICAS

As Práticas são formas de atingir as metas estabelecidas pelos Alfas. Desde a fase de levantamento de requisitos e pesquisa com usuários até a implementação de práticas de organização. Comparando com métodos convencionais como o *Scrum*, práticas como o *Daily Scrum*, o *Sprint Planning* e as retrospectivas são centrais para o ciclo de desenvolvimento. Essas práticas se alinham bem com as sugeridas pela Essence, como prototipação, validação contínua e *feedback* rápido dos usuários. A grande diferença é que, enquanto o *Scrum* define um conjunto específico de práticas, a Essence permite que as equipes escolham as práticas que melhor se adaptam à sua realidade, sejam elas baseadas em *Scrum*, *Kanban*, ou outros métodos.

Cada prática também segue um ciclo de interação com as partes interessadas e as oportunidades de melhoria do sistema. Esse ciclo pode ser descrito em quatro etapas principais:

- Explorar possibilidades: avaliar as oportunidades apresentadas pela criação de um novo sistema ou a melhoria de um existente, analisando os possíveis benefícios e identificando as partes interessadas.

- Compreender as necessidades: trabalhar com as partes interessadas para entender suas necessidades e garantir que os resultados atendam às expectativas.
- Garantir a satisfação: compartilhar os resultados do desenvolvimento e obter a aceitação das partes interessadas, verificando se o sistema atende à oportunidade identificada.
- Utilizar o sistema: acompanhar o uso do sistema em ambiente ativo, observando como ele beneficia as partes interessadas.

Como práticas a serem implementadas, adotamos algumas etapas para organizar e acompanhar o desenvolvimento do projeto. Conforme exibido na Figura 8 a seguir, as práticas adotadas incluem a utilização do *Kanban*, uma ferramenta visual para controle e organização de tarefas.

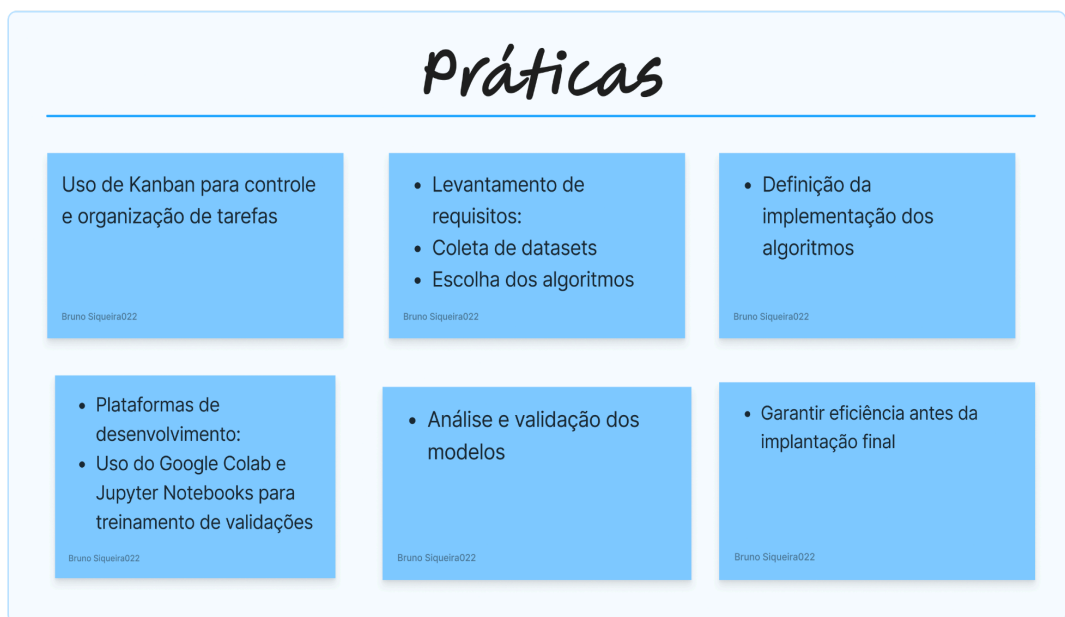


Figura 8 – Demonstração das Práticas do projeto.

Fonte: Elaborado pelo autor.

A Figura 8 apresenta uma visão geral das práticas adotadas para viabilizar o projeto, destacando, entre elas, o uso do *Kanban* como forma de controle das tarefas a serem utilizadas para monitorar a evolução das práticas até o objetivo pré-estabelecido pelos Alfas. Esse sistema envolve o uso de cartões que descrevem as etapas do projeto, desde o levantamento

de requisitos, como a coleta de *datasets*, até a escolha dos algoritmos e a forma como vai ser realizada a sua implementação.

Algumas das tarefas descritas nesses cartões incluem a definição dos critérios para a seleção de dados como qualidade das imagens, fundos a campo e neutros, a avaliação e validação dos algoritmos, e a integração da solução com o ambiente de produção. Cada cartão serve como uma ferramenta de acompanhamento, permitindo visualizar o progresso e identificar possíveis obstáculos e ajustar as atividades conforme necessário.

Durante o desenvolvimento, utilizamos plataformas como o *Google Colab* e *Jupyter Notebooks*, Essas ferramentas permitem testar de forma simplificada algoritmos em ambientes de nuvem, sem a necessidade de realizar muitas configurações para rodar o algoritmo e garantir que ele reconheça a placa de vídeo com suporte ao *TensorFlow* e *PyTorch*. Essas ferramentas facilitam a prototipação, análise e validação dos modelos, garantindo que eles sejam otimizados e funcionem de forma eficiente antes da implantação final. Além disso, para garantir a acessibilidade ao produtor, o projeto utiliza bibliotecas como *Keras*, que simplificam a implementação dos modelos de *machine learning*.

### 3.3 COMPETÊNCIAS

As Competências envolvem as habilidades e capacidades necessárias para realizar as tarefas, como desenvolvimento e integração contínua, garantindo que o sistema se mantenha útil e escalável ao longo do tempo. No que diz respeito à solução, a equipe deve ser capaz de entender e analisar requisitos, construir e operar um sistema que atenda a esses requisitos. Para isso, é necessário que a equipe possua três competências principais:

- **Análise:** Capacidade de transformar oportunidades e necessidades das partes interessadas em um conjunto coerente de requisitos.
- **Desenvolvimento:** Habilidade de projetar e desenvolver sistemas eficazes, de acordo com os padrões estabelecidos.
- **Teste:** Competência para testar o sistema, garantindo que ele seja utilizável e atenda aos requisitos estabelecidos.

No aspecto de Competências, foram estabelecidos requisitos técnicos necessários para o desenvolvimento dos algoritmos e da interface final acessível ao produtor. A Figura 9 ilustra tais requisitos.



Figura 9 – Demonstração das Competências do projeto.

Fonte: Elaborado pelo autor.

Como demonstrado na Figura 9, o conhecimento em bibliotecas de machine learning, como *PyTorch* e *Keras*, é considerado dispensável, enquanto o conhecimento prévio em *Python*, a principal linguagem utilizada no desenvolvimento dos modelos, é essencial. Também é importante ter familiaridade com plataformas como *Google Colab* e *Jupyter Notebooks*, que são utilizadas no ambiente de prototipação e validação dos algoritmos. Para a criação da interface visual de análise, é fundamental o domínio de *React*, uma biblioteca *JavaScript* utilizada para a construção de interfaces. Esse conjunto de habilidades garante que tanto os algoritmos de IA sejam testados quanto a interface seja desenvolvida de maneira eficiente e de forma acessível visualmente ao produtor.

## 4 ALGORITMOS DE *MACHINE LEARNING* PARA DETECÇÃO DE DOENÇAS

Para a implementação dos algoritmos de detecção de ferrugem asiática em folhas de soja, a primeira etapa consistiu no levantamento dos dados a serem utilizados. Foram coletadas imagens tanto de folhas saudáveis quanto de folhas infectadas em diferentes ambientes, seja com fundo de campo, quanto fundos neutros. Esse processo é necessário para garantir um conjunto de dados robusto e balanceado, capaz de fornecer informações visuais suficientes para o treinamento dos modelos de aprendizado de máquina. A seguir, a Seção 4.1 detalha o processo de coleta dos dados, enquanto a Seção 4.2 aborda a escolha dos algoritmos, com foco na *ResNet50* (Seção 4.2.1) e nos *Vision Transformers* (Seção 4.2.2).

### 4.1 COLETA DE DADOS

A coleta inicial foi planejada de forma que ambos os grupos folhas saudáveis e folhas infectadas pela ferrugem asiática fossem representados de forma balanceada, para que o modelo tivesse um peso de aprendizado eficaz para ambas as classes. Ao todo, foram coletadas 1000 imagens de folhas saudáveis e 1000 imagens de folhas infectadas, buscaram-se imagens com fundos mais semelhantes a campo para tentar imitar uma aplicação natural, mas algumas das imagens apresentavam fundos neutros, como branco e preto, mas úteis para garantir a generalização do modelo como recomendado por pesquisadores em visão computacional (Alom et al., 2019).

Os conjuntos de dados foram obtidos de duas fontes principais: o *Kaggle* e o *Mendeley Data*. O *Kaggle*, amplamente reconhecido pela qualidade e diversidade de seus *datasets*, foi selecionado devido à sua confiabilidade, com dados frequentemente preparados por especialistas e revisados pela comunidade. Um dos *datasets* utilizados foi o *Plant Disease Classification Merged Dataset*, preparado por Dobrovsky (2022). Já o *Mendeley Data*, uma plataforma voltada para o compartilhamento de dados acadêmicos, forneceu o *Dataset of Soybean Leaf Images for Disease Classification*, organizado por Feng (2020). Por fim, o *Harvard Dataverse* contribuiu com o *dataset* Imagens de ferrugem asiática (*Phakopsora pachyrhizi*) em folhas de soja, publicado por Galvani Filho e Da Silva (2020), contendo imagens específicas da doença alvo deste estudo. A combinação dessas fontes contribuiu para a diversidade e a abrangência dos dados, abrangendo variações de cor, textura e formato das folhas, o que é essencial para que o modelo generalize e reconheça padrões de maneira eficaz, independentemente das condições específicas das imagens.

Para que o modelo consiga identificar a diferença entre uma folha saudável e uma folha infectada pela ferrugem asiática, ele deve aprender a reconhecer características específicas, como tons marrons e manchas que surgem na folha, conforme ilustrado na Figura 10. Esses traços ajudam o modelo a aprender a reconhecer padrões de infecção que não estão presentes em folhas saudáveis.



Figura 10: Imagem de folha de soja infectada por ferrugem asiática.  
Fonte: Galvani (2020).

A Figura 10 ilustra um exemplo de folha infectada usada no treinamento. A imagem mostra os padrões de lesões e mudanças de cor que o modelo precisa identificar. Essas características visuais foram fundamentais para ensinar o modelo a distinguir com precisão folhas saudáveis daquelas afetadas pela doença, garantindo que ele reconheça esses sinais mesmo quando há variações nas condições da imagem.

De forma complementar, a Figura 11 apresenta um exemplo de uma folha saudável utilizada no treinamento. A imagem destaca sua cor uniforme e a ausência de manchas características que o modelo aprende a reconhecer como indicadoras de uma planta em boas condições.



Figura 11 – Imagem de folha de soja saudável.

Fonte: Bevers, Sikora E Hardy (2022).

Após a coleta, as imagens foram separadas em duas categorias: folhas saudáveis e folhas infectadas. A separação adequada das imagens garante a qualidade do treinamento dos modelos de aprendizado de máquina. Dados mal classificados podem resultar em um mau treinamento e, conseqüentemente, em um modelo incapaz de reconhecer corretamente as diferenças entre folhas saudáveis e doentes, prejudicando o desempenho do algoritmo. Após a separação e classificação completa, todo o *dataset* foi enviado para o *Google Drive*. Dentro dessa pasta, os dados foram organizados em subpastas de folhas saudáveis e folhas infectadas, facilitando o consumo pelos modelos no *Google Colab*.

#### 4.2 ESCOLHA DOS ALGORITMOS

A escolha dos algoritmos de *machine learning* para a detecção de doenças nas folhas foi baseada em critérios de desempenho, incluindo resultados em competições como o ImageNet, além da escolha de modelos específicos para a análise de imagens, complexidade do modelo e capacidade de generalização para diferentes contextos. Com base nesse critério foram selecionados dois principais tipos de modelos: Redes Neurais Convolucionais, como o *ResNetv50* (He et al., 2016), e *Vision Transformers* (Park, 2022), que representa uma abordagem mais recente para o processamento de imagens.

#### 4.2.1 ResNetv50

O algoritmo *ResNetv50* (*Residual Network*) foi escolhido por sua ampla abordagem em outros trabalhos de pesquisa, o que demonstra sua aplicabilidade em diferentes contextos e devido ao seu desempenho no ImageNet, um dos maiores e mais reconhecidos desafios de classificação de imagens. Em 2015, a *ResNetv50* apresentou resultados significativos, vencendo a competição e demonstrando sua capacidade de treinar redes profundas sem sofrer do problema de degradação do gradiente, comum em arquiteturas mais antigas (He et al., 2016).

Para evitar a degradação do gradiente, o modelo *ResNetv50* introduziu camadas residuais, conforme ilustrado na Figura 12. Essa figura apresenta a arquitetura da *ResNetv50* e destaca como as camadas residuais permitem que a informação flua de forma mais eficiente entre as diferentes profundidades da rede, garantindo um treinamento estável e eficaz.

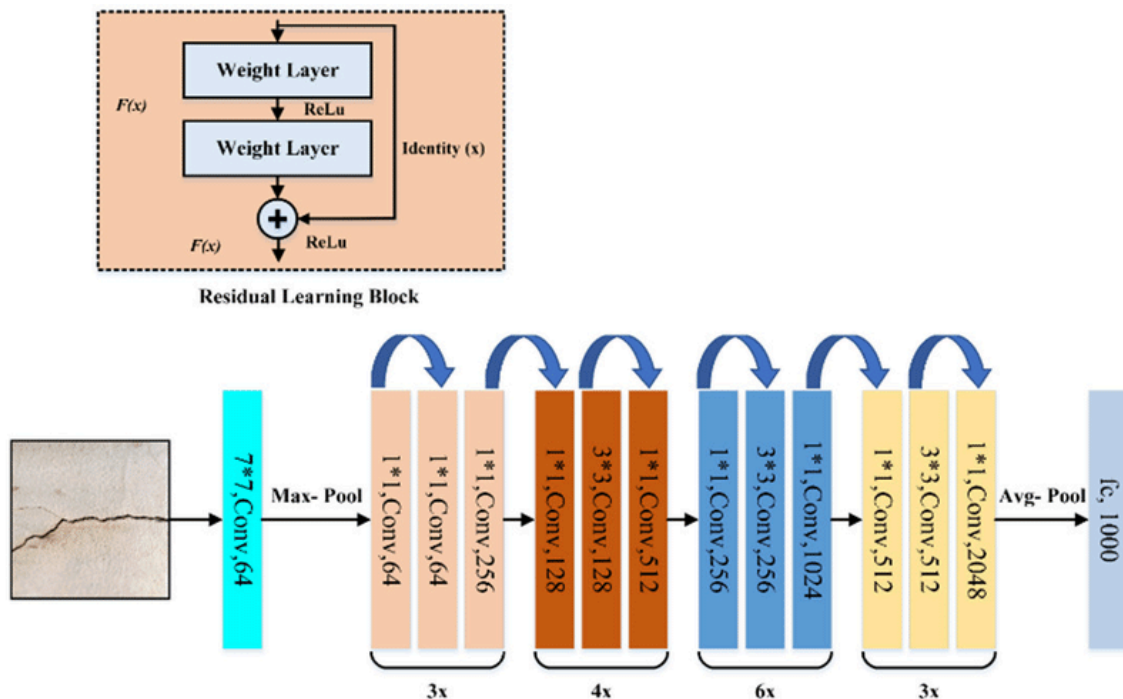


Figura 12 – Visão geral da arquitetura do algoritmo *ResNetv50*.

Fonte: Ali et al. (2021).

A principal inovação da *ResNetv50* está no conceito de camadas residuais, que dão origem ao seu nome. Essas camadas permitem a preservação do gradiente em redes muito profundas, facilitando o treinamento e garantindo que o modelo possa aprender características

mais complexas. Como demonstrado pelas setas azuis da Figura 11, a cada passagem pela rede, as camadas residuais verificam se o desempenho do treinamento está melhorando ou piorando. Caso não haja melhoria, a informação da camada anterior é preservada e trazida para a camada atual, evitando que características aprendidas de forma ineficaz sejam repassadas para camadas futuras. Essa capacidade torna a *ResNet* particularmente adequada para a detecção de doenças em folhas, uma vez que a identificação de padrões sutis exige uma rede profunda e bem treinada.

#### 4.2.2 Vision Transformers

Os *Vision Transformers* (ViTs) foram escolhidos por representarem uma tecnologia de ponta na área de visão computacional. Ao contrário das *CNNs*, que utilizam convoluções para extrair características das imagens, os ViTs utilizam o mecanismo de atenção, permitindo que diferentes partes da imagem sejam analisadas de forma independente, mas em conjunto, capturando padrões globais e locais de forma mais eficaz (Park, 2022). A Figura 13 apresenta a arquitetura ViT, demonstrando como o modelo realiza a classificação de imagens e utiliza o mecanismo de atenção para focar em diferentes partes da imagem.

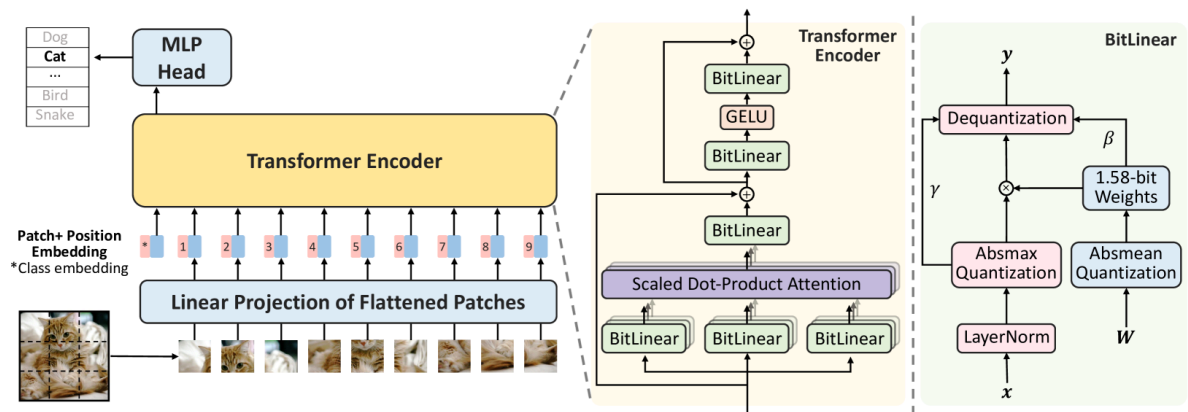


Figura 13 – Visão geral do ViT-1.58b.  
 Fonte: Adaptado de Yuan et al. (2024).

Basicamente, os ViTs funcionam dividindo a imagem em partes menores, chamadas *patches* como demonstrado na Figura 12. Nesse exemplo, a imagem de um gato foi dividida em pequenos segmentos, que foram "tokenizados" para serem processados de forma

individual. Cada um desses *patches* é transformado em uma representação vetorial e, em seguida, enviado ao *Transformer Encoder*, que utiliza o mecanismo de atenção para analisar as partes de maneira conjunta. Dessa forma, cada *patch* é analisado no contexto da imagem completa, permitindo que o modelo compreenda tanto os padrões de cada *patch*, quanto os padrões gerais da imagem. Ao final, na última camada, o modelo realiza a classificação da imagem, determinando a classe à qual ela pertence com base no aprendizado prévio.

A arquitetura ViTs oferece a capacidade de lidar com imagens com grandes variações e de aprender padrões que podem ser difíceis de capturar utilizando redes convolucionais tradicionais. Dessa forma, os ViTs se mostram uma escolha promissora para a tarefa de identificação de imagens, onde diferentes padrões e anomalias precisam ser identificados com precisão.

## 5 RESULTADOS

A aplicação dos algoritmos foi realizada utilizando o *Google Colab*, em uma instância equipada com uma *GPU NVIDIA T4*. Essa máquina, disponibilizada pelo Colab, possui uma GPU dedicada focada em testes de algoritmos que necessitam de processamento de placa gráfica, contendo 16 GB de memória RAM, 16 GB de memória da GPU e 120 GB de armazenamento para o sistema. Essa infraestrutura possibilitou a execução eficiente dos modelos, aproveitando o suporte da GPU para acelerar os processos além de ser gratuito o acesso a essas máquinas, assim garantindo a capacidade de processamento necessária para lidar com o conjunto de dados e as demandas computacionais dos algoritmos empregados.

Durante os testes, foram aplicados algoritmos de visão computacional, como o *ResNetv50* e *Vision Transformers* (ViTs), a fim de avaliar o desempenho na identificação da ferrugem asiática em folhas de soja e obter os objetivos definidos nos Alfas. A seguir, são apresentados como foi mais especificamente as Práticas segundo a Essence sendo feito essa implementação dos algoritmos e as taxas de aprendizado e os resultados, incluindo métricas de desempenho como acurácia, precisão, recall e tempo de processamento para cada modelo.

Inicialmente foi realizado a separação dos dados e uma pré-análise, inserindo uma variação a mais além do contido no *dataset* montado, como variações de ângulo, zoom, cores das imagens, para garantir uma boa generalização do modelo.

O *dataset* estava armazenado diretamente no *Google Drive*, uma plataforma de armazenamento em nuvem, ela é integrada diretamente ao *Google Colab*, facilitando o consumo do *dataset* para o treinamento sem precisar realizar o upload das pastas de imagens diretamente para a máquina do *Colab*. Após essa etapa, os dados são divididos em 80% para treino e 20% para validação, garantindo um conjunto balanceado para o treinamento e validação do modelo.

### 5.1 RESNETV50

O primeiro modelo a ser testado foi o *ResNetv50* pré-treinado com os dados do ImageNet. As imagens do *dataset* utilizadas foram redimensionadas para um tamanho padrão de 224×224 pixels, o que é comum em muitas redes neurais convolucionais, pois permite uma padronização do input e facilita o treinamento do modelo.

Esse modelo foi configurado com uma taxa de aprendizado chamado de *learning rate* média de  $1e-5$  que é uma taxa de aprendizado mais precisa equivalente a 0,00001. Esse valor relativamente baixo é ideal para um treinamento profundo, pois ajuda a garantir que o ajuste dos pesos seja gradual, evitando grandes oscilações e melhorando a estabilidade do modelo durante o aprendizado. Para auxiliar o modelo e garantir um aprendizado contínuo utilizou-se a função de *callback ReduceLROnPlateau*, que foi utilizada para ajustar dinamicamente a taxa de aprendizado durante o treinamento, com base no comportamento da perda de validação. A ideia por trás dessa estratégia é reduzir a taxa de aprendizado quando o modelo para de melhorar, o que ajuda a evitar grandes oscilações nos valores dos pesos e melhora a convergência do modelo ao longo do treinamento. Além do uso dessa função, foi realizado um pré-treinamento de 20 épocas e um treinamento profundo subsequente de 100 épocas. A estratégia de pré-treinamento ajudou a inicializar os pesos da rede de forma eficiente, permitindo uma convergência mais rápida e estável durante o treinamento profundo.

Durante o pré-treinamento, os pesos da rede foram ajustados para um ponto inicial que facilitou o aprendizado subsequente, prevenindo problemas comuns como a queda do gradiente que nada mais é que uma métrica para o modelo ter um aprendizado contínuo, ou seja, quanto mais próximo de zero esse gradiente chega, menor é o aprendizado do modelo, então se busca manter uma média estável para que o modelo continue a aprender em todas as camadas de treinamento. Para reduzir essa degradação, foi utilizada a função de ativação *ReLU (Rectified Linear Unit)*, que ajuda a manter gradientes não nulos ao permitir apenas valores positivos nas ativações das camadas.

Para auxiliar o modelo foram adicionadas camadas personalizadas ao modelo para a tarefa de classificação. Após a extração das características pela rede base da *ResNet*, foi utilizada uma camada de *GlobalAveragePooling2D* para reduzir a dimensionalidade e sumarizar as informações aprendidas. Em seguida, foram adicionadas duas camadas densas.

Primeira camada densa, com 1024 unidades, ativação *ReLU*, e regularização L2 (0.01) para evitar um super aprendizado dos dados de teste conhecido como *overfitting*. Esta camada foi seguida por uma normalização por lotes chamada *BatchNormalization* ele normaliza as ativações das camadas, ajudando a acelerar e estabilizar o treinamento, além de permitir o uso de taxas de aprendizado mais altas. E uma camada de *Dropout* com taxa de 0.6 que nada mais é que uma forma de evitar o *overfitting*. Na segunda camada densa, com 512 unidades, ativação *ReLU*, e regularização L2 (0.01), também seguida de *BatchNormalization* e uma camada de *Dropout* com taxa de 0.5.

Finalmente, foi adicionada uma camada de saída com 1 unidade e ativação sigmoide, responsável por realizar a classificação binária entre folhas saudáveis e infectadas pela ferrugem asiática. Essa combinação de camadas foi necessária para melhorar a capacidade de generalização do modelo, minimizando problemas de *overfitting* e garantindo uma performance sólida durante o treinamento e a validação.

Além disso, a arquitetura *ResNet* foi implementada, utilizando conexões residuais que auxiliam os gradientes a fluírem sem perdas significativas, permitindo um aprendizado mais eficaz mesmo em redes profundas. A fase de treinamento profundo teve uma continuidade por 100 épocas, sendo fundamental para refinar o modelo e permitir que ele capturasse padrões nos dados de folhas de soja.

Essa abordagem de treinamento em duas etapas foi necessária para melhorar a performance do modelo e obter um melhor resultado. A combinação do pré-treinamento e do treinamento profundo permitiu que a *ResNet* alcançasse uma acurácia significativa, além de precisão e *recall* elevados, garantindo uma identificação robusta da ferrugem asiática em folhas de soja. As métricas de desempenho são apresentadas na Tabela 1, destacando os ganhos obtidos em termos de acurácia e a capacidade de generalização do modelo.

A Tabela 1 apresenta os resultados da classificação das imagens de folhas de soja, distinguindo entre folhas saudáveis e folhas infectadas com ferrugem asiática. As métricas *Precision*, *Recall* e *F1-score* foram utilizadas para avaliar o desempenho do modelo de aprendizado de máquina.

<b>Classe</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F1-score</i></b>	<b><i>Support</i></b>
<b>Folhas saudáveis</b>	0.83	0.02	0.04	240
<b>Folhas com ferrugem</b>	0.47	1.00	0.64	212
<b><i>Accuracy</i></b>	-	-	0.48	452
<b><i>Macro average</i></b>	0.65	0.51	0.34	452
<b><i>Weighted average</i></b>	0.66	0.48	0.32	452

Tabela 1 – Métricas Algoritmo *ResNet*.

Fonte: Elaborado pelo autor.

*Precision* indica a proporção de predições corretas entre todas as predições feitas para uma determinada classe. Por exemplo, para a classe “Folhas Com Ferrugem”, o modelo

apresentou uma *Precision* de 0.47, indicando que 47% das imagens classificadas como “Folhas Com Ferrugem” estavam corretas. *Recall* mede a capacidade do modelo de identificar corretamente os exemplos positivos de uma classe. Para “Folhas Com Ferrugem”, o *Recall* foi de 1.00, indicando que todas as folhas infectadas foram detectadas, mas, para “Folhas Saudáveis”, o *Recall* foi de 0.02, indicando falha completa na detecção dessa classe.

O F1-Score é a média harmônica entre *Precision* e *Recall*, proporcionando uma visão balanceada do desempenho. Um *F1-score* de 0.64 para “Folhas Com Ferrugem” demonstra um bom desempenho nessa classe, enquanto o valor de 0.04 para “Folhas Saudáveis” reforça a dificuldade do modelo em classificar adequadamente essa categoria.

Além disso, o *Accuracy*, que reflete a proporção total de classificações corretas, foi de 48%, indicando que o modelo acertou menos da metade das previsões. A métrica *Macro average* fornece a média dos valores de *Precision*, *Recall* e *F1-score* para todas as classes, ponderada igualmente.

Embora o modelo *ResNet* tenha apresentado um *Recall* perfeito de 1.00 para a classe de folhas com ferrugem, o desempenho extremamente baixo de 0.02 para folhas saudáveis sugere um desequilíbrio do modelo. Esse comportamento pode ser atribuído a fatores como a falta de um *Fine-Tuning* adequado, que limita a capacidade do modelo de identificar padrões específicos do *dataset*, e o leve desequilíbrio na distribuição das classes de validação do modelo de 240 exemplos de folhas saudáveis contra 212 de folhas com ferrugem, que pode ter aumentado esse viés durante o aprendizado. Esses fatores indicam que o modelo aprendeu a priorizar a classe mais frequente ou cujos padrões são mais fáceis de identificar, como a folhas com ferrugem

Outras métricas que podem ser utilizadas para avaliar o desempenho do modelo incluem a Curva de ROC e a matriz de confusão para podermos identificar mais afundo essa diferença da classificação do modelo. A Curva de ROC (*Receiver Operating Characteristic*) é uma ferramenta que mede a capacidade do modelo de distinguir entre as classes, considerando os falsos positivos e os verdadeiros positivos em diferentes limiares de decisão. Quanto mais a curva se aproxima do canto superior esquerdo, melhor o desempenho do modelo.

Como demonstrado na Figura 14, o desempenho do modelo alcançou uma AUC (Área Sob a Curva) de 0.53, indicando um desempenho um pouco acima do que uma classificação de modo aleatório. Isso sugere que o modelo teve dificuldades em distinguir entre as classes, provavelmente devido a limitações nos dados de treinamento, arquitetura ou outros fatores.




Figura 14 – Curva de ROC *ResNet*.

Fonte: Elaborado pelo autor.

Já a matriz de confusão apresenta de forma clara os acertos e erros do modelo, detalhando quantas amostras foram corretamente classificadas (verdadeiros positivos) e onde ocorreram os erros (falsos positivos e falsos negativos). Essa visualização permite identificar quais classes o modelo tem mais dificuldade em classificar corretamente.

A Figura 15 apresenta a matriz de confusão e mostra que o modelo tem 100% de acerto na classe 1 (Folhas Infectadas), mas comete 98% de erros ao classificar a classe 0 (Folhas Saudáveis) como infectadas. Isso indica um forte viés para a classe 1, possivelmente devido ao desbalanceamento nos dados ou dificuldades do modelo em aprender características das folhas saudáveis. Esse comportamento reforça a necessidade de ajustes no treinamento ou no *dataset* para melhorar a generalização.

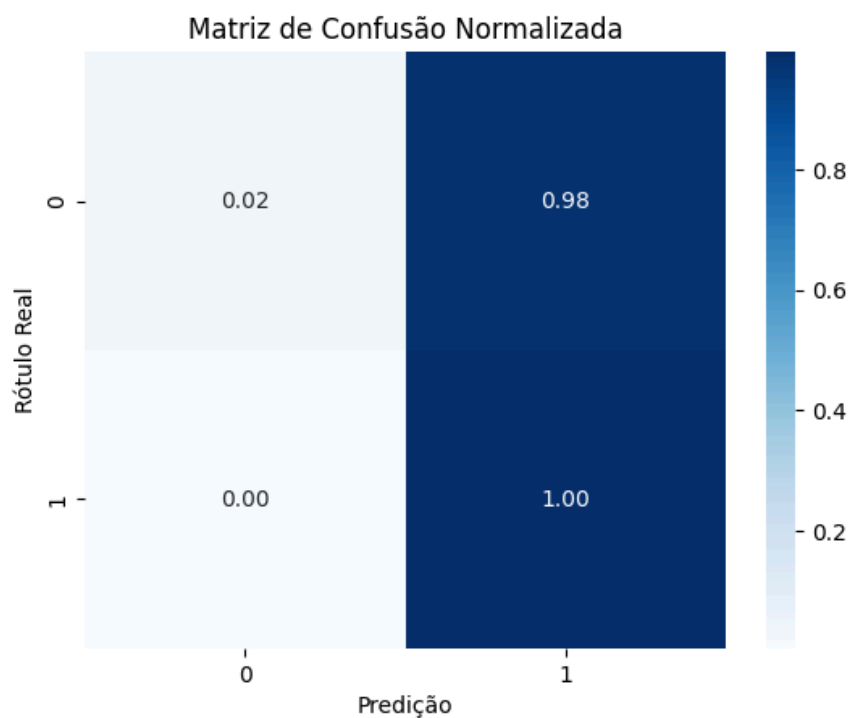


Figura 15 – Matriz de Confusão *ResNet*.

Fonte: Elaborado pelo autor.

Esses resultados sugerem que o modelo apresenta um viés significativo para detectar folhas infectadas, possivelmente devido a uma limitação do algoritmo ou uma configuração enviesada dos hiperparâmetros. A baixa performance na classe “Folhas Saudáveis” indica a necessidade de aprimoramento, como o uso de técnicas de balanceamento de dados ou ajustes nos hiperparâmetros do modelo.

Com o resultado obtido em um dos primeiros testes, buscou-se aprimorar alguns hiperparâmetros com o objetivo de alcançar uma classificação mais precisa ou aceitável para o modelo. Foram ajustados parâmetros como o *learning rate*, que foi alterado de  $1e-5$  para  $1e-4$ , e o *batch size*, que foi modificado de 32 para 64. O *batch size* é o número de amostras que o modelo processa antes de atualizar seus pesos. Com um valor maior de *batch size*, o modelo realiza atualizações mais suaves e estáveis, calculando o erro com base em um maior número de exemplos a cada iteração. Essa mudança pode resultar em uma convergência mais estável.

Um desses resultados obtidos com o *learning rate* de  $1e-4$  e o *batch size* modificado trouxeram alguns valores mais interessantes como apresentados na Tabela 2.

<b>Classe</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F1-score</i></b>	<b><i>Support</i></b>
<b>Folhas saudáveis</b>	0.53	0.38	0.44	240
<b>Folhas com ferrugem</b>	0.47	0.62	0.54	212
<b><i>Accuracy</i></b>	-	-	0.49	452
<b><i>Macro average</i></b>	0.50	0.50	0.49	452
<b><i>Weighted average</i></b>	0.50	0.49	0.49	452

Tabela 2 – Métricas de uma segunda tentativa Algoritmo *ResNet*.

Fonte: Elaborado pelo autor.

Houve algumas mudanças na classificação do modelo, algumas medidas tiveram uma queda, como o *recall* da classe “Folhas com ferrugem” e a *precision* de “Folhas saudáveis”, mostrando que essa alteração dos hiperparâmetros teve uma mudança no aprendizado do modelo. Ao treinar o modelo em diferentes épocas, observou-se que o valor inicial da função de perda era de aproximadamente 12.700. À medida que o treinamento avançava, esse valor foi gradualmente diminuindo, atingindo 3.500 após várias iterações.

A função de perda é uma métrica que mede a discrepância entre as previsões do modelo e os valores reais. Durante o treinamento, o objetivo é minimizar essa função, ou seja, fazer com que o modelo se aproxime cada vez mais dos valores corretos. A redução do *loss* ao longo das épocas indica que o modelo está aprendendo a fazer previsões mais precisas e ajustando seus pesos para melhorar seu desempenho em relação aos dados de treinamento.

Com esses resultados dos primeiros testes já se pode obter um conhecimento prévio do modelo e quais parâmetros ajustar para que esse tenha um bom desempenho na classificação de imagens. Buscou-se ajustar métricas diferentes das definidas nos testes anteriores como a redução do pré-processamento das imagens, remoção do zoom e rotação tanto para cima quanto para baixo. Além disso, considerou-se uma configuração maior da resolução de entrada das imagens de 224x224 para 512x512, ajustes no *Dropout* e remoção de certos *BatchNormalization* para garantir que o modelo tenha mais dados para treinar conforme as suas camadas mais densas. Ao longo das épocas viu-se que o modelo apresentava um *loss* gradual baixo, e atingindo uma acurácia boa no treinamento, mas ao chegar nos dados de validação do modelo, percebia-se que ele tinha um viés equivocado com esses dados ou, nesse

questo, ele ficou ótimo em decorar os dados (*overfitting*), mas na sua validação acabou vendo padrões diferentes do apresentado no treino. A Tabela 3 apresenta os resultados obtidos após esse ajuste dos parâmetros.

<b>Classe</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F1-score</i></b>	<b><i>Support</i></b>
<b>Folhas saudáveis</b>	0.50	0.00	0.01	240
<b>Folhas com ferrugem</b>	0.47	1.00	0.64	212
<b><i>Accuracy</i></b>	-	-	0.47	452
<b><i>Macro average</i></b>	0.48	0.50	0.32	452
<b><i>Weighted average</i></b>	0.49	0.47	0.30	452

Tabela 3 – Métricas do 3 teste ResNet.

Fonte: Elaborado pelo autor.

Como apresentado na Tabela 3, pode-se perceber alguma alteração nos valores medidos, mas ainda sim o modelo não apresenta um resultado eficiente na classificação, mesmo o modelo apresentando uma acurácia de 99% na validação ao exibir outras métricas nota-se que ele tende a ficar perdido ainda, não apresentando uma boa generalização.

## 5.2 VISION TRANSFORMERS

O segundo modelo a ser treinado e validado foi o *Vision Transformers*, um modelo mais atual e mais robusto em técnicas de visão computacional. Ele teve um pré-treinamento de 10 épocas e um treinamento profundo de 100 épocas, o mesmo feito no *ResNet*, para fazer com que eles tenham a mesma taxa de aprendizado.

Durante o treinamento, o *ViT* teve os seus requisitos de treinos atendidos como a divisão das imagens no seu tamanho necessário de 224×224 pixels, o teste foi feito com um modelo pré-treinado chamado *vit\_base\_patch16\_224*, esse modelo possui um número intermediário de parâmetros, o que o torna menos exigente em termos de recursos, mas ainda assim viável para obter bons resultados. Além disso, iniciou-se com pesos pré-treinados em um *dataset* genérico do modelo *vit base*, o que melhorou a generalização de aprendizado do modelo. Utilizou-se a função de perda *CrossEntropyLoss*, juntamente com o otimizador Adam, com uma taxa de aprendizado inicial de  $1e-4$  que é uma taxa de aprendizado inicial

bem pequena equivalente a um ajuste de 0,0001. O *ViT*, por ser um modelo mais robusto e estruturado, não exigiu tantas configurações adicionais ou adaptações nos hiper parâmetros como o *ResNet*, simplificando o processo de ajuste para alcançar uma boa performance.

Após feito todo o treinamento buscou-se utilizar a mesmas métricas do *ResNet* para medir o desempenho do *ViT*, como a curva de ROC, matriz de confusão e a tabela de F1-Score como demonstrado na Tabela 4, assim buscando uma análise justa de ambos os modelos com as mesmas métricas de desempenho.

<b>Classe</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F1-score</i></b>	<b><i>Support</i></b>
<b>Folhas saudáveis</b>	0.99	0.99	0.99	240
<b>Folhas com ferrugem</b>	0.99	0.99	0.99	212
<b><i>Accuracy</i></b>	-	-	0.99	452
<b><i>Macro average</i></b>	0.99	0.99	0.99	452
<b><i>Weighted average</i></b>	0.99	0.99	0.99	452

Tabela 4 – Métricas *Vision Transformers*.

Fonte: Elaborado pelo autor.

Como demonstrado na Tabela 3 o modelo está praticamente perfeito, com um F1-score elevado de 0.99 para ambas as classes e precisão, recall e acurácia também em 99%. O melhor limiar de decisão é 0.94, o que maximiza o equilíbrio entre falsos positivos e falsos negativos. Esses resultados indicam que o modelo foi extremamente eficaz em identificar corretamente folhas saudáveis e com ferrugem. Para ter outros pontos de vista e não se limitar a apenas a tabela de f1-score utilizou-se a curva ROC, apresentada na Figura 16, ela avalia a capacidade do modelo de distinguir entre as classes os falsos positivos e verdadeiros positivos.




Figura 16 – Curva de ROC do *Vision Transformers*.

Fonte: Elaborado pelo autor.

O modelo alcançou uma AUC (Área Sob a Curva) de 1.00 para ambas as classes Folhas Saudáveis e Folhas Com Ferrugem, indicando que o modelo conseguiu classificar perfeitamente todas as amostras, separando completamente as duas classes. Essa performance ideal é refletida pela curva que atinge o canto superior esquerdo do gráfico, superando significativamente a linha tracejada, que representa um classificador aleatório (AUC = 0.5).

Além disso, a matriz de confusão, exibida na Figura 17, detalha os acertos e erros do modelo, cada célula da matriz foi normalizada para mostrar proporções em relação ao total de exemplos, variando de 0 a 1.

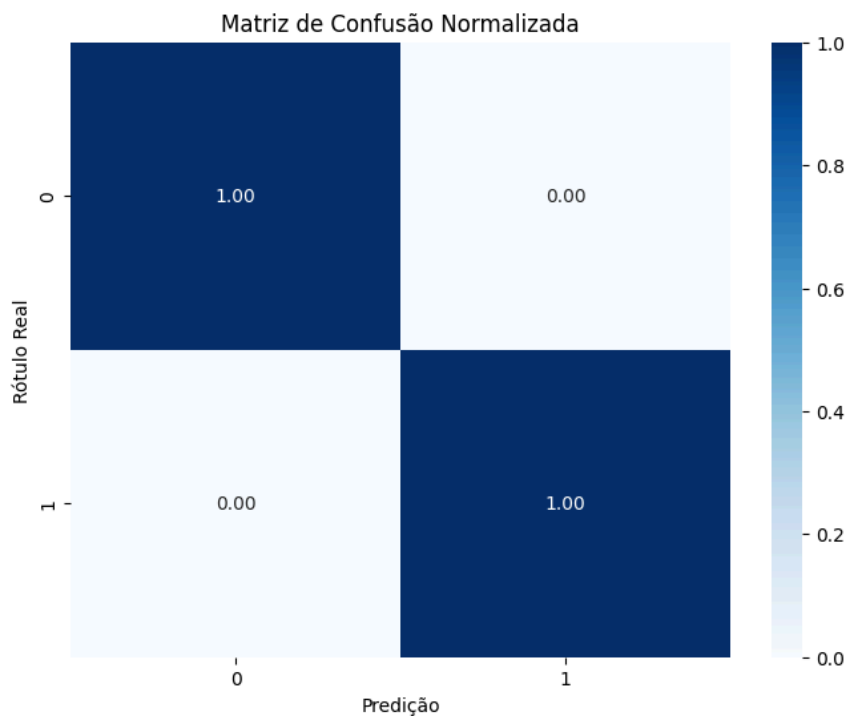


Figura 17 – Matriz de Confusão do *Vision Transformers*.

Fonte: Elaborado pelo autor.

A Figura 17 apresenta a matriz de confusão normalizada, evidenciando o desempenho do modelo, com 100% de acertos em ambas as classes: O rótulo real traz o desempenho das classes Folhas Saudáveis (classe 0) e Folhas Com Ferrugem (classe 1). A diagonal principal, cor em azul-escuro, apresentando que todas as amostras foram corretamente classificadas, enquanto os valores fora da diagonal, cores claras são zero, indicando a ausência de falsos positivos e falsos negativos. Esses resultados confirmam que o modelo separou perfeitamente as classes, assim não necessitando de mais testes nesse conjunto de dados.

### 5.3 DISCUSSÃO

A avaliação e comparação entre os modelos *Vision Transformer* (ViT) e *ResNet* foi realizada com base em métricas como acurácia, F1-Score, matriz de confusão e curva ROC. O objetivo foi analisar o desempenho de cada modelo e sua capacidade de generalização no contexto da classificação de folhas saudáveis e folhas infectadas com a ferrugem asiática. O *Vision Transformer* apresentou resultados superiores em todas as métricas, alcançando uma separação perfeita entre as classes, com  $AUC = 1.00$  na curva *ROC*, além de uma matriz de confusão que não registrou falsos positivos nem falsos negativos. Por outro lado, o modelo

*ResNet*, embora apresentava uma redução na sua função de perda e aumentava sua acurácia a cada época, apresentou erros de classificação que impactaram sua AUC e outros indicadores.

Ambos os modelos foram submetidos às mesmas condições experimentais, incluindo um pré-treinamento de 10 épocas e um treinamento profundo de 100 épocas. Além disso, utilizaram a mesma função de perda *CrossEntropyLoss* e o otimizador Adam com uma taxa de aprendizado inicial de  $1e-4$  para o *ViT* e uma inicial de  $1e-5$  para o *ResNet*, garantindo condições comparáveis para avaliação. Enquanto o *ViT* demonstrou maior capacidade de generalização e eficiência, o *ResNet*, mostrou-se mais limitado em capturar padrões sutis entre as classes. Esse resultado reflete as diferenças fundamentais entre as arquiteturas, sendo que o *ViT* utiliza uma abordagem baseada em atenção para aprender relações globais e locais nos patches de imagem, enquanto o *ResNet* depende de convoluções tradicionais para extração de características. Apesar do desempenho excelente do *ViT*, a ausência de erros (falsos positivos e falsos negativos) observada na matriz de confusão deve ser interpretada com cautela. É possível que a simplicidade do *dataset* tenha favorecido a classificação perfeita. Em cenários mais complexos ou com *datasets* menos estruturados, o desempenho do modelo pode variar. Além disso, é importante considerar que o *Vision Transformer* requer mais recursos computacionais do que o *ResNet*, o que pode representar uma limitação em aplicações reais onde o hardware disponível é fraco.

No *hardware* utilizado para os testes, o *ResNet* demonstrou um desempenho superior, não exigindo recursos mais avançados e alcançando um tempo médio de treino de 1h30min. Por outro lado, o modelo *ViT* demandou maior capacidade da máquina, resultando em um tempo de treino mais elevado, em torno de 2h30min. Mas ambos os modelos demonstraram potencial na tarefa de classificação, mas apresentam características distintas que podem ser exploradas dependendo do contexto. O *ViT* mostrou-se superior no cenário avaliado, mas a *ResNet*, por ser menos complexa computacionalmente, ainda pode ser uma escolha eficiente para problemas menos exigentes. No futuro, a ampliação do *dataset*, bem como a introdução de maior diversidade nos dados, podem ajudar a validar melhor a capacidade de generalização dos modelos em cenários reais. Assim, a escolha entre as duas arquiteturas dependerá não apenas da performance, mas também de fatores como custo computacional e características específicas do problema em questão.

Com isso, podemos deduzir que o uso de modelos de *machine learning* pode e deve ser introduzido nas práticas agronômicas, trazendo facilidade para o produtor e permitindo que ele esteja sempre à frente do mercado e de seus concorrentes. Dessa forma, ele poderá

oferecer um produto de melhor qualidade aos consumidores, além de reduzir gastos relacionados ao combate de doenças, como a ferrugem asiática. Destacando que o líder está sempre preparado para enfrentar as diversas mudanças e desafios. Essa visão está ligada diretamente a um dos dotes da *forma mentis* do líder, segundo Meneghetti(2022) no ponto 11, que o líder bem alinhado com seus propósitos deve vigiar e analisar constantemente o surgimento de tecnologias que podem se tornar um ótimo produto, logo ele deve examinar e validar se ela irá trazer ou não uma mudança significativa na sua empresa. Tendo em vista essas mudanças sempre alinhadas com o seu escopo principal do seu negócio.

Ou seja, o produtor, como líder de seu empreendimento, deve estar atento às novidades que impactam seu setor. Essa postura permite que ele se mantenha à frente dos concorrentes, destacando-se como referência em sua região ao utilizar tecnologias como abordadas neste trabalho. Assim, a capacidade de adotar mudanças estratégicas reforça sua liderança e fortalece o posicionamento no mercado.

#### 5.4 IMPLEMENTAÇÃO

Visando validar a aplicação dos algoritmos de IA na detecção de ferrugem asiática, foi desenvolvida uma interface simples, intuitiva e acessível, permitindo que o produtor rural envie imagens diretamente de seu dispositivo móvel. O algoritmo *Vision Transformers* realiza a análise da imagem e apresenta os resultados de forma clara e rápida na palma da mão do produtor, facilitando a tomada de decisões para o manejo das lavouras e contribuindo para a melhoria da produtividade e facilidade do dia a dia do produtor.

A interface foi projetada para atender a um dos requisitos principais dos Alfas, que era garantir a facilidade de uso e o acesso direto para o produtor. E como definido nas competências exigidas, a aplicação foi desenvolvida utilizando React, uma tecnologia de desenvolvimento web. A escolha sobre utilizar a tecnologia foi por familiaridade e conhecimento prévio na linguagem. Além disso, optou-se pela construção de uma *Progressive Web Application* (PWA), um tipo de aplicação que pode ser utilizada tanto em navegadores quanto instalada diretamente no dispositivo móvel do usuário, para facilitar o acesso tanto ao produtor sem necessidade de instalações de aplicativos por meio de lojas como *Apple Store* e *Play Store*. Com essa abordagem, o produtor pode acessar a ferramenta em qualquer lugar, desde que tenha uma conexão com a internet, e realizar o envio das imagens para análise.

A Figura 18 apresenta a tela inicial da interface da aplicação. Nela o produtor pode carregar a imagem tanto através da galeria de imagens do dispositivo, quanto tirando diretamente uma foto através da câmera.

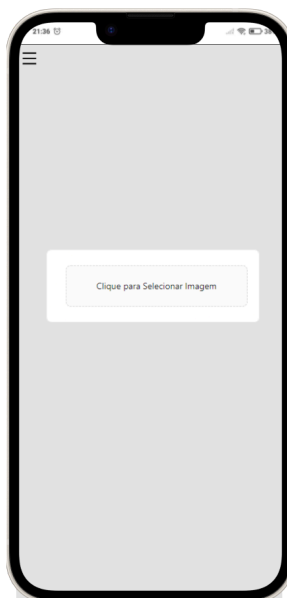


Figura 18 – Aplicação do algoritmo *Vision Transformers*: escolha de imagem.

Fonte: Elaborado pelo autor.

A Figura 18 apresenta a aplicação do algoritmo onde basta apenas o produtor submeter a imagem da sua galeria e ela será encaminhada a uma aplicação *front-end* e será feito o processamento da imagem para *base64* codificação que converte dados binários (como imagens ou arquivos) em uma string de caracteres, assim facilitando a comunicação pela internet entre a aplicação e a leitura do algoritmo, após a conversão ela será enviada a um *back-end* construindo com *FastApi* em *Python* a linguagem necessária para o teste da validação dos algoritmos.

Foi escolhido construir uma *FastApi* com *Python* por ser uma abordagem rápida e eficiente de lidar com a comunicação do *front-end* com a implementação do modelo que está em *Onnx*. Esse formato é utilizado para auxiliar a implementação entre diferentes *frameworks* de aprendizado de máquina, facilitando a integração e a execução do modelo em diversos ambientes.

Após todo o processamento realizado pelo modelo, ele é tratado pelo back-end para ter um retorno claro e manipulável pelo *front-end* de forma que ele exiba isso para o produtor. A Figura 19 apresenta como o produtor tem o resultado da avaliação do modelo.



Figura 19 – Aplicação do algoritmo *Vision Transformers*: classificação da folha de soja.

Fonte: Elaborado pelo autor.

A Figura 19 apresenta o retorno da análise de forma clara e simples, exibindo a imagem enviada e o resultado da classificação, indicando se a imagem pertence à classe saudável ou infectada, com as respectivas porcentagens de certeza. Como ilustrado na Figura 19, foi submetida uma imagem de fundo de campo, que foi corretamente classificada como saudável, com 100% de certeza, evidenciando o desempenho do modelo *Vision Transformers* no processo de treinamento.

Além disso, foi disponibilizado o teste para um produtor que possa testar essa ferramenta e fornecer uma opinião técnica para validar se essa solução agrega um valor que facilite o seu dia a dia na detecção de ferrugem asiática. A aplicação *front-end* foi hospedada na plataforma *Vercel*, que permite o envio de páginas *web* de forma gratuita. Já a aplicação *back-end* foi disponibilizada em uma máquina local, utilizando um processo chamado *tunneling*, que torna a aplicação local acessível pela *web*. Esse processo é realizado através da ferramenta *Ngrok*, que encaminha todas as solicitações do *front-end* para a máquina local onde o modelo treinado está em execução.

Os testes realizados indicaram que a ferramenta foi bem recebida, especialmente pela sua simplicidade e rapidez na análise. De acordo com o um produtor a região central do estado do Rio Grande Do Sul, Formigueiro , “A ferramenta possui uma interface simples e fácil de se utilizar, ela responde rápido após o envio da imagem, ela tem uma classificação aceitável”. Essa análise reforça a confiabilidade da ferramenta para o uso em larga escala e a necessidade de aumento dos dados de treino para que o modelo se torne mais generalista em algumas imagens a campo. A Figura 20 apresenta uma das classificações feita pela ferramenta.

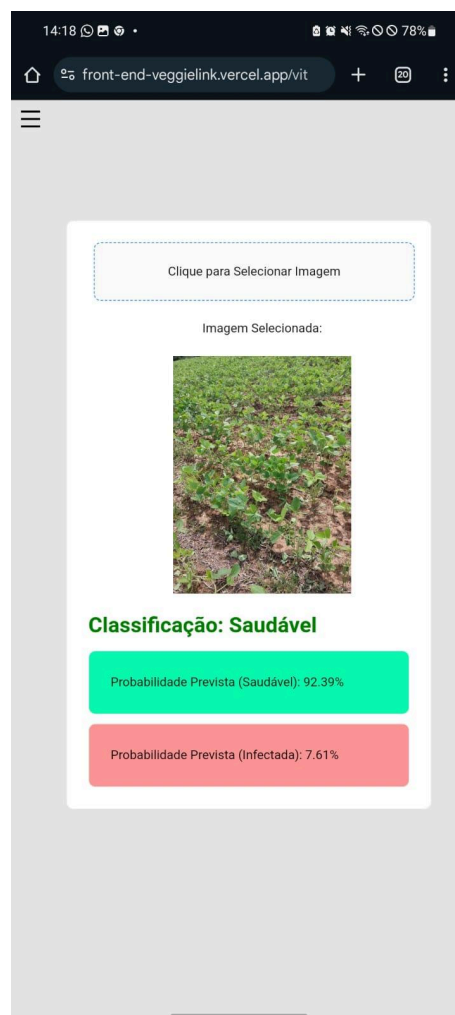


Figura 20 – Aplicação do algoritmo *Vision Transformers*: classificação da folha de soja em campo.

Fonte: Elaborado pelo autor.

A Figura 20 apresenta uma classificação boa em uma imagem tirada a campo mesmo a imagem sendo uma variação muito distante do *dataset* utilizado para treino, pois a grande maioria das imagens eram voltadas as folhas da soja e não especificamente a campo.

Em outras áreas que o produtor realizou o teste, ele havia feito aplicação de herbicida para o controle de ervas daninhas, assim elas apresentam uma cor amarela, prejudicando a detecção do algoritmo como apresentado na Figura 21.



Figura 21 – Aplicação do algoritmo *Vision Transformers*: classificação da folha de soja em campo.

Fonte: Elaborado pelo autor.

Como apresentado na Figura 21 o modelo obteve uma classificação equivocada assim apresentando um falso positivo, provavelmente devido à coloração ao redor das plantas de soja.

Com esses resultados o modelo *Vision Transformers* se mostra promissor na classificação das folhas de soja, claro ele ainda enfrenta algumas limitações em certos cenários a campo, mas com uma integração desse modelo ao campo real pode-se obter resultados ainda mais satisfatórios, além dessa maior variação no *dataset* de treino pode-se

realizar a integração de ferramentas mais robustas para cobertura em grande área, como a utilização de drones para o mapeamento das lavouras.

Os resultados obtidos e o feedback dos usuários, podemos concluir que a aplicação da IA na detecção de ferrugem asiática, aliada a uma interface amigável e acessível, tem o potencial de contribuir significativamente para a produtividade agrícola, oferecendo aos produtores uma ferramenta de diagnóstico eficiente e prática.

## 6 CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo explorar a aplicação de algoritmos de inteligência artificial para a identificação de doenças em folhas de soja, especificamente a ferrugem asiática, que representa uma ameaça significativa à produtividade agrícola. Nesse contexto, buscou-se integrar avanços tecnológicos à agricultura, contribuindo para práticas mais sustentáveis e eficientes no setor. A análise focou em algoritmos de aprendizado de máquina, com ênfase em técnicas modernas, como redes neurais convolucionais e *Vision Transformers*, que apresentam grande potencial na identificação de doenças por meio de imagens.

Ao longo do estudo, foram implementados e avaliados dois modelos principais: o *ResNetv50* e o *Vision Transformers*. O modelo *ResNet* apresentou limitações, com um desempenho inferior devido à dificuldade em distinguir folhas saudáveis de infectadas. Por outro lado, o *Vision Transformers* destacou-se com resultados praticamente perfeitos em métricas como precisão, recall e *F1-score*, mostrando ser altamente eficaz para a tarefa. Esses achados reforçam a viabilidade do uso de tecnologias de inteligência artificial no agronegócio, destacando seu impacto positivo na otimização de recursos e na mitigação de perdas causadas por doenças agrícolas.

Com um resultado do teste desses modelos, buscou-se projetar uma solução de fácil acesso aos produtores com o modelo *Vision Transformers* pelo seu bom desempenho, que o produtor tenha acesso de forma simplificada e um retorno rápido e eficiente sobre a planta que ele possui uma dúvida se ele necessita realizar uma aplicação de defensivo contra a ferrugem asiática, no momento em que ele envia sua imagem da planta que ele acredita estar infectada pode obter o resultado na palma de sua mão sem necessitar que um especialista olhe a sua lavoura ou que ele aplique um defensivo onde não necessita, assim otimizando o seu tempo e custo de produção. Com uma interface simples onde qualquer produtor com uma experiência média com um celular ou navegação em aplicativos realize a sua análise.

Com a avaliação dos produtores conclui-se que o trabalho mostrou a viabilidade da aplicação de IA, especificamente com o uso do *Vision Transformers* e como tal modelo pode representar um avanço significativo na agricultura de precisão. Suportado por essa tecnologia, é possível oferecer aos produtores ferramentas poderosas para otimizar suas operações e melhorar a produtividade, ao mesmo tempo em que se reduzem custos e impactos ambientais.

No futuro, planeja-se avaliar a integração do modelo desenvolvido com tecnologias baseadas em drones, o que ampliaria ainda mais a cobertura da área analisada, permitindo que

grandes lavouras sejam monitoradas de forma mais eficiente e automatizada. Tal integração potencializa a detecção de doenças em tempo real, oferecendo aos produtores dados mais precisos e detalhados sobre a saúde das suas plantas. Além do uso de drones, considera-se aumentar a cobertura da aplicação com a inclusão do teste de outras variedades de doenças da soja, tais como a antracnose, e outras variedades de plantas como feijão, arroz, milho e café, possibilitando atingir cada vez mais setores do agronegócio.

## REFERÊNCIAS

Ali, Luqman & Alnajjar, Fady & Jassmi, Hamad & Gochoo, Munkhjargal & Khan, Wasif & Serhani, Mohamed. (2021). **Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures**. *Sensors*. 21. 1688. 10.3390/s21051688.

ALMEIDA, A.; CARVALHO, F.; MENINO, F. **Introdução ao Machine Learning**. Disponível em: <<https://dataat.github.io/introducao-ao-machine-learning/index.html>>. Acesso em: 28 sep. 2024.

ALOM, Md. Zahangir; TAHA, Tarek; YAKOPCIC, Chris; WESTBERG, Stefan; SIDIKE, Paheding; NASRIN, Mst; HASAN, Mahmudul; VAN ESSEN, Brian; AWWAL, Abdul; ASARI, Vijayan. **A state-of-the-art survey on deep learning theory and architectures**. *Electronics*, v. 8, p. 292, 2019. DOI: 10.3390/electronics8030292.

ALPAYDIN, Ethem. **Machine Learning**. Cambridge, MA: MIT Press, 2016.

BEVERS, N.; SIKORA, E. J.; HARDY, N. B. **Pictures of diseased soybean leaves by category captured in field and with controlled backgrounds: Auburn soybean disease image dataset (ASDID)**. Dryad., 2022.

BORÉM, A. et al. **Agricultura Digital**. 2.ed. São Paulo: Oficina de Textos, 2021.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Exportações do agronegócio brasileiro atingem mais de US\$ 15 bilhões em maio. 2024**. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/exportacoes-do-agronegocio-brasileiro-atingem-mais-de-us-15-bilhoes-em-maio>. Acesso em: 21 set. 2024.

BUAINAIN, ANTÔNIO MÁRCIO-CAVALCANTE, PEDRO - CONSOLINE, LETÍCIA. **Estado atual da agricultura digital no Brasil: Inclusão dos agricultores familiares e pequenos produtores rurais**. LC/TS.2021/61: CEPAL, junho 2021.

CARR, N. **The shallows: What the internet is doing to our brains**. Nova Iorque, NY, USA: WW Norton, 2011.

**Com agricultura de precisão, produtores rurais alcançam até 29% de aumento na produtividade. 17 de maio de 2021.** Disponível em: <<https://portal.sistemafamasul.com.br/noticias/com-agricultura-de-precis%C3%A3o-produtores-rurais-alcan%C3%A7am-at%C3%A9-29-de-aumento-na-produtividade>>. Acesso em: 24 sep. 2024.

DOBROVSKY, Aline. **Plant disease classification merged dataset: Soybean rust.** 2022. Disponível em: [https://www.kaggle.com/datasets/alinedobrovsky/plant-disease-classification-merged-dataset?select=Soybean\\_\\_rust](https://www.kaggle.com/datasets/alinedobrovsky/plant-disease-classification-merged-dataset?select=Soybean__rust). Acesso em: 18 nov. 2024.

DOMINGOS, Pedro. **The Master Algorithm: How the Quest for the Ultimate Learning Machine will Remake our World.** New York: Basic Books, 2015.

**Doenças.** (2008) Portal Embrapa. Disponível em: <https://www.embrapa.br/hortalicas/pimenta/doencas> . Acesso em: 22 jul. 2024.

ENJOY ALGORITHMS. **Supervised, unsupervised, and semi-supervised learning.** Disponível em: <https://www.enjoyalgorithms.com/blogs/supervised-unsupervised-and-semisupervised-learning>. Acesso em: 18 nov. 2024.

FENG, Zhe. **Dataset of soybean leaf images for disease classification.** 2020. Disponível em: <https://data.mendeley.com/datasets/bycbh73438/1>. Acesso em: 18 nov. 2024.

Galvani Filho, M. E.; Da Silva, A. R., 2020, "**Imagens de ferrugem asiática (Phakopsora pachyrzi) em folhas de soja**", <https://doi.org/10.7910/DVN/1FYAGO>, Harvard Dataverse, V1, UNF:6:d42sUR2dDcoy06Zg352qrw== [fileUNF]

Gatkal, N. R., Nalawade, S. M., Sahni, R. K., Bhanage, G. B., Walunj, A. A., Kadam, P. B., & Ali, M. (2024). **Review of IoT and electronics enabled smart agriculture. International Journal of Agricultural & Biological Engineering**, 17(5), 1–14. <https://doi.org/10.25165/j.ijabe.20241705.8496>

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning.** Cambridge: MIT Press, 2016

GUO, G.; WANG, H.; BELL, D.; BI, Y.; GREER, K. **KNN model-based approach in classification.** In: **ON THE MOVE TO MEANINGFUL INTERNET SYSTEMS 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, 2003, Catania, Sicily. Proceedings [...].** Berlin: Springer Berlin Heidelberg, 2003. p. 986-996.

Hafeez, A., Husain, M. A., Singh, S. P., Chauhan, A., Khan, M. T., Kumar, N., Chauhan, A., & Soni, S. K. (2023). **Implementation of drone technology for farm monitoring & pesticide spraying: A review.** *Information Processing in Agriculture*, 10(2), 192-203. <https://doi.org/10.1016/j.inpa.2022.02.002>

Hartman, G. L., Rupe, J. C., Sikora, E. J., Domier, L. L., Davis, J. A., & Steffey, K. L. (Eds.). (2015). **Compendium of soybean diseases and pests** (5th ed.). American Phytopathological Society.

HE, K.; ZHANG, X.; REN, S.; SUN, J. **Deep residual learning for image recognition.** In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE, 2016. p. 770–778. DOI: 10.1109/CVPR.2016.90. Disponível em: <https://arxiv.org/abs/1512.03385>. Acesso em: 18 nov. 2024.

HERBERT, S. **Alimentando o Mundo: O Surgimento da Moderna Economia Agrícola no Brasil.** [s.l.: s.n.].

IVAN, G. A. | **Biotecnologia Agrícola no Brasil: Oportunidades e desafios da inovação nos próximos dez anos.** [s.l.] LUMEN JURIS, 2023.

KAGGLE. **Sivam Dataset of soybean diseased leaf.** 2021. Disponível em: <https://www.kaggle.com/datasets/sivm205/soybean-diseased-leaf-dataset>. Acesso em: 18 nov. 2024.

KLERKX, Laurens; JAKKU, Emma; LABARTHE, Pierre. **A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda.** *NJAS - Wageningen Journal of Life Sciences*, v. 90-91, p. 100315, 2019. DOI: <https://doi.org/10.1016/j.njas.2019.100315>.

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). **Gradient-based learning applied to document recognition.** *Proceedings of the IEEE*, 86(11), 2278-2324.

MASSRUHÁ, S. M. et al. **A transformação digital no campo rumo à agricultura sustentável e inteligente.** 2020. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/217698/1/LV-Agricultura-digital2020-cap1.pdf>. Acesso em: 25 set. 2023.

MENEGHETTI, ANTONIO. **Projeto líder: a inteligência empresarial na ótica de Antonio Meneghetti.** Recanto Maestro, São João do Polêsine, RS: Fundação Antonio Meneghetti, 2022. 245 p.

Ministério da Agricultura, **Pecuária e Abastecimento. Atração de Investimentos.** Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/relacoes-internacionais/atracao-de-investimentos>. Acesso em: 24 set. 2024.

Obaideen, K., Yousef, B. A. A., AlMallahi, M. N., Tan, Y. C., Mahmoud, M., Jaber, H., & Ramadan, M. (2022). **An overview of smart irrigation systems using IoT.** Energy Nexus, 7, 100124. <https://doi.org/10.1016/j.nexus.2022.100124>

**O que são Redes Neurais? Importância e Como Funciona?** Com.br Opencadd Advanced Technology Comércio e Serviços Ltda, , 5 maio 2022. Disponível em: <https://www.opencadd.com.br/blog/o-que-sao-redes-neurais>. Acesso em: 19 nov. 2024

PARK, N., & KIM, S. (2022). **How do vision transformers work?**. arXiv preprint arXiv:2202.06709.

PICCOLO, E. A., DE SOUZA, L. D. F. R., GALLO, Z., & DOS ANJOS OLIVEIRA, T. (2024). **A INTELIGÊNCIA ARTIFICIAL APLICADA NO AGRONEGÓCIO: UMA REVISÃO BIBLIOGRÁFICA.** Revista Contemporânea, 4(6), e4596-e4596.

RAJAGOPAL, M. K., & MURUGAN, M. S. (2023). **Artificial Intelligence based drone for early disease detection and precision pesticide management in cashew farming.** arXiv preprint arXiv:2303.08556. Disponível em: <https://arxiv.org/abs/2303.08556>

RAMOS, Pedro et al. **Dimensões do agronegócio brasileiro. Políticas, instituições e perspectivas.**[S. l.: s. n.], 2017.

SAMUEL, ARTHUR L. 1959. **Some Studies in Machine Learning Using the Game of Checkers**. IBM Journal of Research and Development 3 (3). IBM: 210–29.

SINHA, D. **Improve accuracy and robustness of vision AI apps with vision Transformers and NVIDIA TAO**. 25 jul 2023 Disponível em: <<https://developer.nvidia.com/blog/improve-accuracy-and-robustness-of-vision-ai-apps-with-vision-transformers-and-nvidia- tao/>>. Acesso em: 7 out. 2024.

SUTTON, R. S.; BARTO, A. G. et al. **Reinforcement learning: An introduction**. [S.l.]: MIT press, 1998.

TABOSA, J. M., DE OLIVEIRA, A. S., & HAYAMA, A. D. O. F. (2024). Redes neurais aplicadas na identificação da ferrugem da soja. Cuadernos de Educación y Desarrollo, 16(1), 1978-1993.

TAO, C. et al. **Empowering agrifood system with artificial intelligence: A survey of the progress, challenges and opportunities**. 2023. Disponível em: <<http://arxiv.org/abs/2305.01899>>

Tecnologia, I. ([s.d.]). **PIB do Agronegócio Brasileiro** - Centro de Estudos Avançados em Economia Aplicada - CEPEA-Esalq/USP. 20 de julho de 2024Disponível em : <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx> Acesso em : 19 jul 2024.

**What is support vector machine?** Ibm.com, 13 ago. 2024. Disponível em: <<https://www.ibm.com/topics/support-vector-machine>>. Acesso em: 7 out. 2024

ZHANG, Q. (ED.). **Precision agriculture technology for crop farming**. Londres, England: CRC Press, 2016.