

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**NATHAN PATRIKE DA LUZ WEBER**

**DETECÇÃO DE DOENÇAS FOLIARES EM IMAGENS COM  
APRENDIZADO PROFUNDO: ESTUDOS DE CASO PARA MÍLDIO EM  
SOJA E ÁCARO EM LICHIEIRA**

**DOIS VIZINHOS**

**2022**

**NATHAN PATRIKE DA LUZ WEBER**

**DETECÇÃO DE DOENÇAS FOLIARES EM IMAGENS COM  
APRENDIZADO PROFUNDO: ESTUDOS DE CASO PARA MÍLDIO EM  
SOJA E ÁCARO EM LICHIEIRA**

**Detection of leaf diseases in images with Deep Learning: case studies for  
Mildew in Soybean and Mite in Lychee Tree**

Trabalho de Conclusão de Curso de Graduação  
apresentado como requisito para obtenção do  
título de Bacharel em Engenharia de Software  
do Curso de Bacharelado em Engenharia de  
Software da Universidade Tecnológica Federal  
do Paraná.

Orientador: Prof. Dr. André Roberto  
Ortoncelli

Coorientador: Prof. Dr. Francisco Carlos  
Monteiro Souza

**DOIS VIZINHOS**

**2022**



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

**NATHAN PATRIKE DA LUZ WEBER**

**DETECÇÃO DE DOENÇAS FOLIARES EM IMAGENS COM  
APRENDIZADO PROFUNDO: ESTUDOS DE CASO PARA MÍLDIO EM  
SOJA E ÁCARO EM LICHIEIRA**

Trabalho de Conclusão de Curso de Graduação  
apresentado como requisito para obtenção do  
título de Bacharel em Engenharia de Software  
do Curso de Bacharelado em Engenharia de  
Software da Universidade Tecnológica Federal  
do Paraná.

Data de aprovação: 24/junho/2022

---

André Roberto Ortoncelli  
doutorado  
Universidade Tecnológica Federal do Paraná

---

Francisco Carlos Monteiro Souza  
doutorado  
Universidade Tecnológica Federal do Paraná

---

Marlon Marcon  
doutorado  
Universidade Tecnológica Federal do Paraná

---

Maristela Dos Santos Rey  
doutorado  
Universidade Tecnológica Federal do Paraná

**DOIS VIZINHOS**  
**2022**

Tempo e momentos foram sacrificados para o desenvolvimento deste trabalho, em virtude disso, dedico-lhe a minha mãe Rosane, meu pai Hermes, minha avó Ana e a você Alesandra.

## **AGRADECIMENTOS**

Primeiramente, a Deus, por me permitir ter saúde e dedicação para realização desse trabalho.

Aos meus orientadores por toda a paciência, ajuda, correções e ensinamentos.

A professora Maristela Dos Santos Rey, que auxiliou no projeto, principalmente nas atividades relacionadas a produção da base de dados.

Ao professor Marlon Marcon, que emprestou seu computador para executarmos os experimentos.

Aos meus pais, minha família e minha namorada, por sempre me apoiarem.

À instituição de ensino UTFPR, por tudo o que aprendi ao longo dos anos do curso.

E a todos aqueles que contribuíram, de alguma forma, para a realização deste trabalho.

“Quando algo é importante o suficiente, você  
realiza mesmo que as chances não estejam a  
seu favor.”  
Elon Musk

## RESUMO

A detecção de doenças foliares é uma tarefa importante, pois quanto mais eficiente e eficaz for a realização dessa atividade, maiores são as chances de sucesso no tratamento da planta. Nesse contexto é relevante o desenvolvimento de técnicas que automatizem essa atividade. Este trabalho tem o objetivo de analisar o desempenho de técnicas de Aprendizado Profundo na classificação automática de doenças em imagens de folhas de Lichieira e de Soja. A soja foi escolhida em virtude de exercer um papel fundamental para o desenvolvimento social e econômico de várias regiões do Brasil, o qual é um dos maiores produtores mundiais deste grão. A Lichieira foi selecionada por se tratar de uma planta cultivada principalmente no Brasil, sendo uma árvore para qual existe escassez de alternativas para o controle e manejo de pragas e doenças. A metodologia utilizada pra execução deste trabalho pode ser resumida em duas atividades principais: i) Produção da base de dados experimental; e ii) Condução de estudos de casos com Redes Neurais Convolucionais. A nova base de dados produzida para o projeto é composta por 2288 imagens: 268 folhas de soja com míldio (doença causada pelo fungo *Peronospora Manshurica*), 1000 fotos de folhas de lichia com injúrias provocadas pelo ácaro da erinose (*Aceria Litchii*) e 1020 imagens de folhas de lichia sem o efeito desse ácaro. Destaca-se que a quantidade de imagens de soja é menor devido aos índices baixos pluviométricos na região de Dois Vizinhos (no final de 2021 e início de 2022), que impactaram em percas de produtividade e na baixa proliferação de doenças que precisam de alta umidade. Após a coleta desses dados, as imagens foram rotuladas por uma especialista com doutorado em Fitopatologia. Analisando a revisão de literatura conduzida, foi possível identificar que a base de dados PlantVillage (que possui 54305 imagens, divididas em 38 classes) é a principal base explorada em trabalhos relacionados a detecção de doenças em imagens com características similares as coletadas neste trabalho: fotos tiradas individualmente para cada folha com um fundo uniforme. Também foi possível identificar cinco Redes Neurais Convolucionais (AlexNet, DenseNet169, Inceptionv3, ResNet34 e VGG13) que apresentam acurácia superiores a 99.2% com a base de dados PlantVillage. Esses cinco modelos foram selecionados para o estudo de caso deste trabalho, que também foi conduzido com outras três Redes Neurais Convolucionais mais recentes: EfficientNetB7, MobilenetV2 e SqueezeNet. Para cada uma das oito rede neurais selecionadas foram realizados experimentos com três estratégias de treinamento: i) Ajuste fino (atualiza apenas as camadas totalmente conectadas de uma CNN pré-treinada); ii) Treinamento do zero (aplica o ajuste fino em todas as camadas da rede e inicia a otimização de retro-propagação a



partir da rede pré-treinada); e iii) Treinamento profundo (consiste em treinar a rede do zero a partir de uma configuração aleatória de pesos, não utilizando transferência de aprendizado). Os experimentos deste trabalho foram realizados em três etapas, cada uma com uma instância diferente da base de dados. Em todas as etapas, 80% das imagens compuseram o conjunto de treinamento e 20% delas fizeram parte do conjunto de teste. Na primeira etapa, as oito RNCs foram treinadas com o conjunto composto por 57308 imagens: 2288 fotos de folha de Soja e Lichia coletadas para este trabalho, 54305 da PlantVillage, e 715 fotos com fundos aleatórios (que é uma estratégia utilizada em trabalhos relacionados para obter uma acurácia mais precisa em uma rede neural profunda). Para cada uma das estratégias de treinamento aplicadas na primeira etapa dos experimentos, foi selecionada a RNC que obteve a melhor acurácia, que foi aplicada nos estudos de casos subsequentes. No segundo estudo de caso as RNCs foram treinadas com as 2020 imagens de folhas de Lichia coletadas para este projeto. Já no terceiro estudo de caso, se utilizou um conjunto de 5358 imagens: 5090 folhas de sojas saudáveis da PlantVillage, e 268 folhas de soja com míldio coletadas para este estudo. Na primeira etapa, a melhor resultado foi obtido com a DenseNet169 (com a estratégia de treinamento profundo) que obteve uma acurácia de 99.75%. Para a classificação de apenas folhas de Lichia (com e sem Ácaro), a melhor acurácia foi de 94.80%, alcançada também com a DenseNet169 (com a estratégia de treinamento ajuste fino). Já para o terceiro estudo de caso, realizado apenas com folhas de soja, se obteve uma acurácia de 100% também com a DenseNet169 (em duas estratégias de treinamento: ajuste fino e treinamento profundo). Com os resultados obtidos foi possível analisar pontos positivos e limitações do estudo de caso, e propor temas de trabalhos futuros que podem contribuir para melhorar os resultados obtidos.

**Palavras-chave:** doenças de plantas; visão computacional; aprendizado profundo; rede neural convolucional.

## ABSTRACT

The detection of foliar diseases is an important task, because the more efficient and effective this activity is, the greater the chances of success in the treatment of the plant. In this context, the development of techniques that automate this activity is relevant. This work aims to analyze the performance of Deep Learning techniques in the automatic classification of diseases in images of Lichieira and Soybean leaves. Soybean was chosen because it plays a fundamental role in the social and economic development of several regions of Brazil, which is one of the world's largest producers of this grain. Lichieira was selected because it is a plant grown mainly in Brazil, being a tree for which there is a shortage of alternatives for the control and management of pests and diseases. The methodology used to carry out this work can be summarized in two main activities: i) production of the experimental database, and ii) Conducting a case study with Convolutional Neural Networks. The database produced is composed of 2288 images: 268 soybean leaves with mildew (a disease caused by the fungus *Peronospora Manshurica*), 1000 photos of lychee leaves with injuries caused by the Ehinosis mite (*Aceria Litchii*) and 1020 images of lychee leaves without the effect of this mite. It is noteworthy that the amount of soybean images is lower due to the low rainfall in the Dois Vizinhos region (at the end of 2021), which impacted productivity losses and the low proliferation of diseases that require moisture. After collecting these data, the images were labeled by a specialist with a doctorate in Phytopathology. With the literature review carried out, it was possible to identify that the PlantVillage database (which has 54305 images, divided into 38 classes) is the main base explored in works related to the detection of diseases in images with similar characteristics to those collected in this work – photos taken individually for each sheet with a uniform background. It was also possible to identify five Convolutional Neural Networks (AlexNet, DenseNet169, Inceptionv3, ResNet34 and VGG13) that present greater than 99.2% accuracy with the PlantVillage database. These five models were selected for the case study of this work, which was also conducted with three other more recent Convolutional Neural Networks: EfficientNetB7, MobilenetV2, and SqueezeNet. For each of the eight selected neural networks, experiments were carried out with three training strategies: i) fine-tuning (updating only the fully connected layers of a pre-trained CNN); ii) training from scratch (applies fine-tuning to all layers of the network and starts optimization back propagation from the pre-trained network); and iii) deep training (consists of training the network from scratch using a random configuration of weights, not using transfer learning). The experiments of this

work were carried out in three stages, each with a different instance of the database. At all stages, 80% of the images made up the training set, and 20% of them were part of the test set. In the first stage, the eight RNCs were trained with a set of 57308 images: 2288 photos of Soybean and Lychee leaves collected for this work, 54305 from PlantVillage, and 715 photos with random backgrounds (which is a strategy used in related works to obtain more accurate accuracy in a deep neural network). For each of the training strategies applied in the first stage of the experiments, the RNC that obtained the best accuracy was selected, which was applied in subsequent case studies. In the second case study, the RNCs were trained with the 2020 images of Lychee leaves collected for this project. In the third case study, a set of 5358 images was used: 5090 healthy soybean leaves from PlantVillage, and 268 soybean leaves with mildew collected for this study. In the first stage, the best result was obtained with DenseNet169 (with the deep training strategy) which obtained an accuracy of 99.75%. For the classification of only Lychee leaves (with and without mite), the best accuracy was 94.80%, achieved with DenseNet169 (with the fine-tuning training strategy). As for the third case study, carried out only with soybean leaves, an accuracy of 100% was also obtained with DenseNet169 (in two training strategies: fine-tuning and deep training). With the results obtained, it was possible to analyze positive points and limitations of the case study and to propose themes for future work that can contribute to improving the results obtained.

**Keywords:** plant disease; computer vision; deep learning; convolutional neural network.

## LISTA DE FIGURAS

|  |           |
|--|-----------|
| <b>Figura 1 – Interação: planta, patógeno, meio ambiente, homem e tempo . . . . .</b>  | <b>19</b> |
| <b>Figura 2 – Folhas de Soja com Míldio e sem Míldio . . . . .</b>   | <b>20</b> |
| <b>Figura 3 – Fotos da Licheira e da Lichia . . . . .</b>  | <b>21</b> |
| <b>Figura 4 – Folhas de lichia com e sem ácaro . . . . .</b>   | <b>21</b> |
| <b>Figura 5 – Áreas relacionadas com a Inteligência Artificial . . . . .</b>   | <b>22</b> |
| <b>Figura 6 – Etapas do uso de Visão Computacional para detecção de doenças foliares</b>   | <b>23</b> |
| <b>Figura 7 – Diagrama de distribuição da IA . . . . .</b>   | <b>25</b> |
| <b>Figura 8 – Etapas do treinamento do e aplicação de algoritmos de Aprendizado de<br/>Máquina para identificação de espécies de Plantas . . . . .</b> | <b>26</b> |
| <b>Figura 9 – Pré-processamento - imagem de folha de soja . . . . .</b>  | <b>29</b> |
| <b>Figura 10 – Pré-processamento - imagem de folha de Lichia . . . . .</b>   | <b>30</b> |
| <b>Figura 11 – Gráfico da Acurácia - Primeiro Estudo de Caso . . . . .</b>   | <b>33</b> |
| <b>Figura 12 – Gráfico da Acurácia - Segundo Estudo de Caso . . . . .</b>  | <b>35</b> |
| <b>Figura 13 – Gráfico da Acurácia - Terceiro Estudo de Caso . . . . .</b>   | <b>36</b> |

## LISTA DE TABELAS

|  |           |
|--|-----------|
| <b>Tabela 1 – Dados sobre a etapa de coletas das imagens . . . . .</b>         | <b>28</b> |
| <b>Tabela 2 – Quantidade de imagens coletadas/selecionadas . . . . .</b>       | <b>28</b> |
| <b>Tabela 3 – Resultados Experimentais - Primeiro Estudo de Caso . . . . .</b> | <b>34</b> |
| <b>Tabela 4 – Resultados Experimentais - Segundo Estudo de Caso . . . . .</b>  | <b>35</b> |
| <b>Tabela 5 – Resultados Experimentais - Terceiro Estudo de Caso . . . . .</b> | <b>36</b> |

## SUMÁRIO

|            |  |           |
|------------|--|-----------|
| <b>1</b>   | <b>INTRODUÇÃO</b>                            | <b>14</b> |
| <b>1.1</b> | <b>Objetivos</b>                             | <b>16</b> |
| 1.1.1      | Objetivo geral                               | 16        |
| 1.1.2      | Objetivos específicos                        | 17        |
| <b>1.2</b> | <b>Organização do texto</b>                  | <b>17</b> |
| <b>2</b>   | <b>ASPECTOS TEÓRICOS</b>                     | <b>18</b> |
| <b>2.1</b> | <b>Doenças Foliares</b>                      | <b>18</b> |
| <b>2.2</b> | <b>Soja</b>                                  | <b>19</b> |
| 2.2.1      | Míldio da Soja                               | 19        |
| <b>2.3</b> | <b>Lichia</b>                                | <b>20</b> |
| 2.3.1      | Ácaro da Erinose na Lichieira                | 21        |
| <b>2.4</b> | <b>Inteligência Artificial</b>               | <b>22</b> |
| <b>2.5</b> | <b>Visão Computacional</b>                   | <b>22</b> |
| 2.5.1      | Processo do uso de Visão computacional       | 23        |
| <b>2.6</b> | <b>Aprendizado de Máquina</b>                | <b>24</b> |
| 2.6.1      | Processo do uso de aprendizado de Máquina    | 25        |
| <b>3</b>   | <b>METODOLOGIA</b>                           | <b>27</b> |
| <b>3.1</b> | <b>Coleta de Dados</b>                       | <b>27</b> |
| <b>3.2</b> | <b>Validação das Imagens</b>                 | <b>28</b> |
| <b>3.3</b> | <b>Pré-processamento das Imagens</b>         | <b>28</b> |
| 3.3.1      | Pré-processamento - folhas de soja           | 29        |
| 3.3.2      | Pré-processamento - folhas de lichia         | 29        |
| <b>3.4</b> | <b>Divisão da Base de Dados</b>              | <b>30</b> |
| <b>3.5</b> | <b>Treinamento dos modelos</b>               | <b>31</b> |
| <b>3.6</b> | <b>Métricas Experimentais</b>                | <b>32</b> |
| <b>4</b>   | <b>RESULTADOS EXPERIMENTAIS</b>              | <b>33</b> |
| <b>4.1</b> | <b>Resultados do Primeiro Estudo de Caso</b> | <b>33</b> |
| <b>4.2</b> | <b>Resultados do Segundo Estudo de Caso</b>  | <b>35</b> |
| <b>4.3</b> | <b>Resultados do Terceiro Estudo de Caso</b> | <b>36</b> |

|            |   |           |
|------------|---|-----------|
| <b>4.4</b> | <b>Análise dos Resultados . . . . .</b> | <b>37</b> |
| <b>5</b>   | <b>CONSIDERAÇÕES FINAIS . . . . .</b>   | <b>39</b> |
|            | <b>REFERÊNCIAS . . . . .</b>            | <b>41</b> |

## 1 INTRODUÇÃO

Estimativas indicam que a população mundial chegue a 9,8 bilhões de pessoas em 2050. De acordo com a Organização das Nações Unidas para a Alimentação e Agricultura, a produção agrícola e pecuária terá que sofrer um aumento de 60% para suprir essa nova demanda. Neste cenário, a produção agrícola necessita passar por adaptações para adquirir maiores ganhos na produtividade (ALEXANDRATOS; BRUINSMA, 2012).

Será um grande desafio elevar a produção em 60% em um intervalo de 40 anos, em face às mudanças climáticas e escassez de recursos naturais, como água e solo. A maior parte desse crescimento deverá vir do aumento da produtividade, ou seja, produzir mais no mesmo espaço, neste cenário o desenvolvimento de novas tecnologias é fundamental.

Além do tamanho da área agrícola, outros fatores impactam diretamente nos resultados obtidos, podendo-se destacar a incidência de pragas. Uma planta está sujeita em todo seu ciclo de vida a diversas doenças que influenciam no seu desenvolvimento (HOFFMANN-CAMPO *et al.*, 2000). Doenças em plantas, consistem em qualquer alteração causada por seres vivos ou não, que alterem o seu metabolismo, levando a queda da produtividade e/ou diminuição da qualidade do produto, inviabilizando seu consumo ou comercialização (LOPES; ÁVILA, 2005).

Nesse contexto, destaca-se que o controle de doenças e injúrias é um desafio tanto para pequenos, quanto para grandes produtores rurais, afetando a agricultura e também impactando na pecuária, ocasionando danos as plantas, as pessoas, ao meio ambiente e a economia (BARBEDO; MEIRA, 2014).

Novas tecnologias podem contribuir nesta situação, um exemplo é a detecção automática de doenças em folhas de plantas, que pode agilizar o tratamento, minimizando a quantidade de recursos e agrotóxicos utilizados, além de diminuir impactos de redução da produção agrícola.

Com base na literatura verifica-se que existe um grande interesse sobre esse tema, motivado pela evolução tecnológica das técnicas de Visão Computacional e Aprendizado de Máquina (AM). Existem vários trabalhos já desenvolvidos para detecção automática de doenças em folhas, tal como é apontado em revisões de literatura recentes realizadas (APPLALANAIDU; KUMARAVELAN, 2021; LU; TAN; JIANG, 2021). Pode-se identificar que os métodos no estado da arte utilizam algoritmos baseados em Aprendizado Profundo (AP) - uma sub-área do AM, que permite modelos computacionais compostos de muitas camadas de processamento aprendam a interpretar dados com vários níveis de abstração.

Mesmo com os trabalhos já publicados, ainda existe espaço para novas contribuições, tais como, melhorar resultados dos algoritmos de classificação e desenvolver estudos direcionados a espécies de plantas não exploradas (ou pouco exploradas). Destaca-se que um dos principais problemas relacionados a classificação automática de doenças foliares em imagens, está relacionado a quantidade insuficiente de bases de dados disponíveis (LECUN; BENGIO; HINTON, 2015).



Com este trabalho pretende-se contribuir com a literatura conduzindo estudos de casos com técnicas de AP aplicadas em uma nova base de dados, produzida como parte deste projeto, com três classes de imagens de folhas: i) 268 imagens de folhas de soja com a doença Míldio; ii) 1000 com folhas de Lichieira com injúrias provocadas pelo ácaro da Erinose (*Aceria Litchii*); e iii) 1020 com folhas de Lichieira sem injúrias provocadas pelo ácaro.

Salienta-se que o conjunto de classes de imagens coletadas para a base de dados, foi selecionado pelos seguintes motivos:

- A soja foi escolhida pois possui um papel econômico muito importante no Brasil, que é um dos maiores produtores mundiais desse grão. Pretendia-se inicialmente coletar imagens de várias doenças na soja, mas devido a falta de chuvas (que impactou a proliferação de doenças e a produção da soja), foi possível obter apenas fotos de folhas de soja com Míldio.
- A Lichia é um fruta de origem chinesa, que no Brasil é cultivada principalmente na região sudeste. Apesar de não ter um fator econômico tão forte quanto a soja, essa árvore foi escolhida pois, seus produtores sofrem com escassez de alternativas para o controle e manejo de pragas e doenças, sendo um dos principais problemas o ácaro da erinose. Destaca-se que não foi possível encontrar outra base de dados na literatura com folhas de lichieira e com as mesmas características das imagens exploradas neste trabalho.

Para este trabalho, foram executados experimentos com oito Rede Neurais Convolucionais (RNCs), das quais cinco (AlexNet, DenseNet169, Inceptionv3, ResNet34 e VGG13) apresentaram acurácia superior a 99.2% em experimentos de classificação da base de dados PlantVillage (HUGHES; SALATHÉ *et al.*, 2015) e as outras três (EfficientNetB7, MobilenetV2 e SqueezeNet) foram selecionadas por serem mais recentes. A PlantVillage foi selecionada por ser a base mais utilizada em trabalhos relacionados a detecção automática de doenças em fotos de folhas coletadas em ambiente controlado (APPLALANAIDU; KUMARAVELAN, 2021).

Para cada uma dessas RNCs os experimentos foram executados com três estratégias de treinamento: i) Ajuste fino (atualiza apenas as camadas totalmente conectadas de uma RNC pré-treinada); ii) Treinamento profundo (aplica o ajuste fino em todas as camadas da rede e inicia a otimização de retro propagação a partir da rede pré-treinada); e iii) Treinamento do zero (consiste em treinar a RNC do zero a partir de uma configuração aleatória de pesos, não utilizando transferência de aprendizado).

Os experimentos realizados foram divididos em três etapas, sendo que em cada etapa foi conduzido um estudo de caso com um conjunto diferente de imagens. A primeira etapa teve como o objetivo de avaliar a capacidade de técnicas de AP distinguirem folhas de Lichia (com e sem Ácaro) e de Soja com Míldio, de outros tipos folhas/doenças. A segunda etapa, avaliou a capacidade de métodos de AP identificarem ataques de Ácaro utilizado apenas folhas de Lichia.

Na terceira etapa, foi avaliada a capacidade de métodos de AP identificarem a presença de Míldio utilizado apenas folhas de soja.

Para todas as instâncias experimentais, 80% das imagens compuseram o conjunto de treinamento e 20% delas fizeram parte do conjunto de teste. Na primeira etapa foram realizados testes com as oito RNCs selecionadas, que foram treinadas com três estratégias distintas. Nas etapas experimentais seguintes, para cada estratégia de treinamento, foi aplicada apenas a RNC que apresentou a melhor acurácia na primeira etapa.

Detalhes dos conjuntos de dados e RNCs utilizadas em cada etapa são descritos a seguir:

- Primeiro estudo de caso: 57308 imagens: 2288 fotos de folhas de Soja e Licheira coletadas para este trabalho, 54305 imagens da base PlantVillage, e 715 fotos com fundos aleatórios (que é uma estratégia utilizada para obter-se uma acurácia mais precisa com RNCs (SLADOJEVIC *et al.*, 2016; BRAHIMI *et al.*, 2018));
- Segundo estudo de caso: 2020 imagens de folhas de Lichia coletadas para este projeto; e
- Terceiro estudo de caso: 5358 imagens: 5090 folhas de sojas saudáveis da PlantVillage e 268 folhas de soja com míldio coletadas para este estudo.

A melhor acurácia nas três etapas do estudo de caso foi obtida sempre com a RNC Densenet169. No primeiro estudo de casos, com a estratégia de treinamento profundo, se obteve uma acurácia de 99.75%. No segundo estudo de casos (folhas Lichia com e sem Ácaro), a melhor acurácia foi de 94.80% (com a estratégia de treinamento ajuste fino). Já para o terceiro estudo de caso, realizado apenas com folhas de soja, se obteve uma acurácia de 100% (em duas estratégias de treinamento: ajuste fino e treinamento profundo). Com os resultados obtidos foi possível analisar pontos positivos e limitações do estudo de caso, e propor temas de trabalhos futuros que podem contribuir para melhorar os resultados obtidos.

Os objetivos e contribuições deste trabalho são destacados na Seção 1.1. A organização do restante desta monografia é apresentada na Seção 1.2, que resume o conteúdo das próximas seções do documento.

## 1.1 Objetivos

Essa Seção apresenta o objetivo geral e os objetivos específicos do trabalho proposto.

### 1.1.1 Objetivo geral

O objetivo geral deste trabalho é analisar o uso de técnicas de Aprendizado Profundo para detecção automática de doenças em imagens de folhas de Soja e Lichieira.

### 1.1.2 Objetivos específicos

Para atingir o objetivo geral, serão realizados os seguintes objetivos específicos, que representam as contribuições deste projeto para a literatura:

- **Produzir e disponibilizar uma nova base de dados de imagens de folhas:** Coletar imagens de folhas de soja com Míldio e de Lichieira com e sem injúrias provocadas pelo ácaro da Erinose. Todas as imagens coletadas serão validadas por uma especialista (Doutora em Fitopatologia) e submetidas a uma etapa de pré-processamento para compor a base de dados.
- **Condução de estudos de caso com Redes Neurais Convolucionais:** conduzir experimentos com RNCs treinadas com a base de dados experimental, visando selecionar um modelo que apresente resultado superior ou próximo ao estado da arte dos algoritmos conduzidos com a base de dados PlantVillage (que é a principal base da literatura, com imagens similares as que foram coletadas para este trabalho).

## 1.2 Organização do texto

O restante desse trabalho está dividido em cinco capítulos:

- **Capítulo 2 - Aspectos Teóricos:** contém uma fundamentação teórica que apresenta os conceitos teóricos necessários para o entendimento deste trabalho.
- **Capítulo ?? - Revisão de Literatura:** apresenta o estado da arte relacionado ao tema proposto, descrevendo as principais bases de dados e técnicas de classificação automática de doenças foliares com base em Visão Computacional. Também apresenta um comparativo dos resultados de alguns dos principais métodos para esse tipo de detecção.
- **Capítulo 3 - Metodologia:** descreve a metodologia planejada para desenvolvimento do projeto, detalhando as atividades que se pretende executar.
- **Capítulo 4 - Resultados Experimentais:** apresenta os resultados dos experimentos conduzidos para classificação automática de doenças foliares e também uma análise dos mesmos.
- **Capítulo 5 - Considerações Finais:** considerações finais sobre o tema, objetivos propostos e contribuições esperadas são apresentadas. Também são apontados os principais riscos do projeto.

## 2 ASPECTOS TEÓRICOS

Esse capítulo tem o objetivo de apresentar a fundamentação teórica necessária para o entendimento deste trabalho. A Seção 2.1 apresenta aspectos teóricos relacionados a doenças foliares. A Seção 2.2 descreve a importância da soja no cenário nacional e mundial e também características da doença Míldio. Na Seção 2.3 são apresentadas informações sobre a produção de Lichia e também características das injúrias provocadas pelo ácaro da Erinose. O conceito de Inteligência Artificial (IA) é apresentado na Seção 2.4. Conceitos de Visão Computacional e seu processo de aplicação do reconhecimento de doenças foliares é apresentado na Seção 2.5. Conceitos de AM e seu processo de aplicação do reconhecimento de doenças foliares é apresentado na Seção 2.6.

### 2.1 Doenças Foliares

As pragas e doenças são um desafio recorrente para pequenos e grandes produtores rurais, afetando o ecossistema rural, desde as plantas, animais, pessoas, meio ambiente e economia. O termo praga se refere a qualquer agente vegetal, animal ou micro-organismo que esteja presente em uma área e que se prolifere de forma desordenada, como: insetos, fungos, bactérias, nematoides, vírus e plantas invasoras (BARBEDO; MEIRA, 2014).

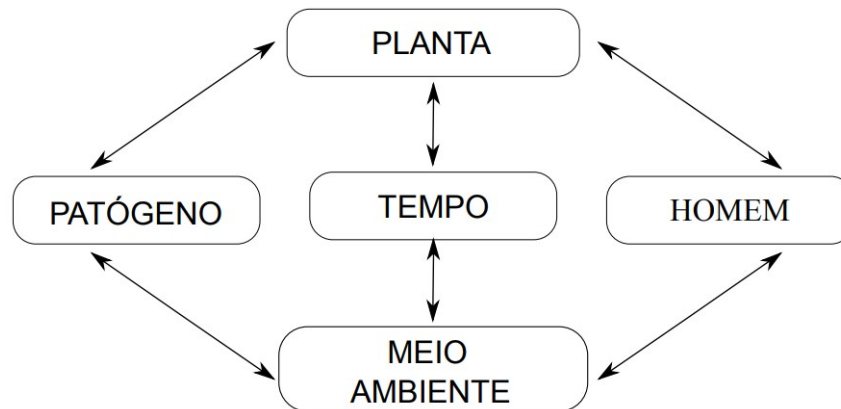
Uma doença de planta, consiste em qualquer alteração causada por seres vivos ou não, que de maneira contínua muda o seu metabolismo, levando a queda de produção e qualidade do produto, inviabilizando seu consumo ou comercialização (LOPES; ÁVILA, 2005). Sendo assim, doenças de plantas são um dos principais limitantes da produção agrícola.

As doenças são resultantes da interação de uma planta com o meio ambiente e um agente patogênico, sendo que nesse sistema o tempo e o ser humano podem ser incluídos. O homem pode reduzir, paralisar ou aumentar os danos causados pelas doenças por meio do manejo da cultura em questão. A Figura 1 ilustra o processo de interação entre essas variáveis (ENRICI, 2018).

Existe uma crescente preocupação em melhorar a produção nas lavouras de maneiras que não agridam o meio ambiente. A inovação tecnológica, como a criação de sistemas que auxiliem nas tomadas de decisão ajudam a atingir esse propósito. Um exemplo é a detecção automática de doenças e injúrias nas folhas da cultura, ajudando a diminuir o dano causado e consequentemente otimizando a produção, além do menor uso de agrotóxicos e outros recursos (DEUS, 2018). O tempo necessário para que as primeiras ações sejam postas em prática também é reduzido, especialmente na ausência de um especialista (BARBEDO; MEIRA, 2014).

A IA, juntamente com a Visão Computacional podem ser uma alternativa para alcançar uma maior produção nas culturas, pois objetivam a criação de algoritmos capazes de interpretar o conteúdo visual de imagens (NEVES; NETO; GONZAGA, 2012).

**Figura 1 – Interação: planta, patógeno, meio ambiente, homem e tempo**



Fonte: Enrici (2018).

## 2.2 Soja

A Soja (*Glycine Max*) está inserida no conjunto de atividades econômicas de maior destaque no mercado mundial, apresentando nas últimas décadas crescimentos expressivos. Neste contexto, o Brasil tem significativa participação na demanda e oferta de produtos do complexo agroindustrial da soja, através de uma evolução constante na sua cadeia produtiva que exerce papel fundamental para o desenvolvimento social e econômico de várias regiões do país (HIRAKURI; LAZZAROTTO, 2014).

O Brasil, os Estados Unidos da América e a Argentina se destacam como os maiores produtores e exportadores de soja em grão no mundo, sendo responsáveis por mais de 80% da produção mundial desse grão, entre os anos de 2002 e 2017 (FIGUEIRA; GALACHE, 2022). Já na safra de 2020/2021, de acordo com um levantamento da Companhia Nacional de Abastecimento, o Brasil foi o maior produtor mundial do grão (CONAB, 2021).


Várias doenças podem incidir no ciclo de desenvolvimento da soja, influenciando diretamente sua produtividade. Neste trabalho é dado foco a classificação automática de Míldio em folhas de soja, por isso a próxima Subseção apresenta detalhes dessa doença.

### 2.2.1 Míldio da Soja

O Míldio é uma doença causada pelo fungo *Peronospora Manshurica*, sendo considerada uma doença secundária da cultura que ocorre frequentemente em lavouras da região sul do Brasil. As condições favoráveis para o seu desenvolvimento são temperaturas acima de 20 °C e alta umidade (KOWATA *et al.*, 2008).

Na soja, o Míldio se manifesta principalmente na frente e verso das folhas conforme é apresentado na Figura 2.

Estudos indicam que O Míldio pode impactar em uma diminuição de produtividade estimada em 8% (KOWATA *et al.*, 2008), devido a redução no peso dos grãos, conforme aumento da severidade da enfermidade nas folhas da soja (SILVA *et al.*, 2016).



### 2.3 Lichia

A Lichieira (*Litchi Chinensis*) é originária no sul da China, foi introduzida no Brasil em 1810, sendo atualmente cultivada principalmente na região sudeste do país, em virtude da melhor adaptação as condições climáticas, pois precisa de clima quente e úmido para seu desenvolvimento e no inverno clima frio e seco para florescimento. Esta espécie quando adulta pode atingir aproximadamente 15 metros de altura e em cultivos comerciais produzir em torno de 300 kg de fruto por planta no ano.

O fruto da Lichieira é conhecido como Lichia, tem formato arredondado e coloração vermelha, envolvendo sua semente com uma polpa, que é uma fonte rica de vitamina C, potássio, cálcio, fósforo e ferro e proteína, podendo ser consumida fresca ou industrializada, na forma de doces, geleias e polpas. Este produto possui alto valor de comercialização em meio a um mercado que está aumentando a demanda por frutas exóticas, possibilitando uma diversificação de renda para os produtores.

A Figura 3 apresenta exemplos de uma Lichieira e também do seu fruto, a Lichia.

Apesar dos fatores positivos relacionados a produção de Lichia, existe uma escassez de alternativas para o controle e manejo de pragas e doenças no cultivo da Lichieira, sendo que a principal incidência que de injurias para essa planta é relacionada o ácaro da Erinose (*Aceria Litchii*), cujos efeitos são descritos na próxima Subseção.

**Figura 3 – Fotos da Licheira e da Lichia**



**Fonte: Autoria Própria.**

### 2.3.1 Ácaro da Erinose na Licheira

O ácaro da Erinose que ataca as folhas da Licheira é o maior problema encontrado na produção de Lichia (SIDDIQUI, 2002; PICOLI *et al.*, 2010). Esse ácaro se instala nas folhas mais novas da planta para se alimentar raspando a epiderme da folha. Existe uma associação entre a raspagem da folha feita pelo ácaro e uma alga que se multiplica nesta folha (GLOBO, 2018).

Os efeitos do ácaro associado com a alga causa enrugamento, bolhas e uma espécie de veludo de coloração marrom, esses efeitos na folha são destacados na Figura 4, que compara a frente e o verso de folhas de lichia com e sem o ataque do ácaro.

**Figura 4 – Folhas de lichia com e sem ácaro**



**Fonte: Autoria Própria.**

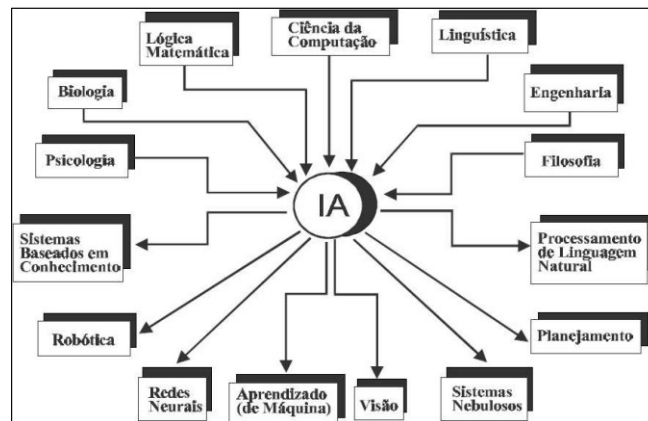
Além de afetar as folhas, o ácaro da Erinose também pode atacar as flores e frutos da Licheira, prejudicando a qualidade das frutas e principalmente a produtividade da planta (SANTOS *et al.*, 2021).

## 2.4 Inteligência Artificial

A IA é uma ciência que surgiu após a Segunda Guerra Mundial. Ela sistematiza e automatiza tarefas, sendo potencialmente relevante para qualquer esfera da atividade intelectual humana (NORVIG; RUSSELL, 2004).

Na Ciência da Computação a IA é um ramo cujo interesse objetiva que os computadores se comportem ou pensem de maneira inteligente. Por se tratar de um tópico muito amplo, IA está relacionada com psicologia, biologia, lógica matemática, linguística, engenharia, filosofia, entre outras áreas científicas. Conforme mostra a Figura 5, as setas de entrada são as bases da IA e as setas de saída são as aplicações da IA (GOMES, 2010).

**Figura 5 – Áreas relacionadas com a Inteligência Artificial**



Fonte: GOMES (2010).

Neste trabalho são exploradas duas áreas da IA, a Visão Computacional e AM, que serão descritas nas Seções 2.5 e 2.6, respectivamente.

## 2.5 Visão Computacional

De acordo com Ramos (2006), a visão é o mais importante e avançado dos sentidos humanos, correspondendo a 75% da percepção. Essa afirmação demonstra a importância das imagens para a compreensão humana do mundo.

Neste sentido, a visão computacional objetiva emular a visão humana, automatizando a interpretação das informações com um conjunto de técnicas e métodos. Recebendo uma imagem como entrada e retornando como saída uma interpretação total ou parcial da mesma (MARENGONI; STRINGHINI, 2009).

Segundo Marengoni e Stringhini (2009), em sistemas de visão computacional na maioria das vezes é necessário serem utilizadas técnicas de processamento digital de imagens. Crosta (1999), mencionam que o processamento digital de imagens visa analisar, alterar e identificar características de uma imagem para extrair informações relevantes e classificá-las, além de filtrá-las e realçá-las para análises posteriores.



Marques Filho e Vieira Neto (1999), comentam que essa área vem sendo objeto de crescente interesse por permitir viabilizar grande número de aplicações em diversos ramos de atividade humana, como Medicina, Biologia, Geografia, Robótica, Agricultura, entre outros. Exemplos de trabalhos nessas áreas são: Macedo (2012) na Medicina, Colella (2012) na Biologia, Shinzato (2010) na Geografia, Quiles e Romero (2004) na Robótica e Filho (2018) na Agricultura.


Detalhes sobre o processo de aplicação de Visão Computacional em diferentes áreas, são apresentados na Subseção 2.5.1.

### 2.5.1 Processo do uso de Visão computacional

Em relação a detecção de doenças foliares, o reconhecimento dos sintomas e sinais é inerentemente visual e requer julgamento, baseado em métodos científicos. Atualmente, na maioria das vezes este processo é feito de forma manual por uma pessoa especializada na área, o que requer uma grande quantidade de trabalho e tempo. Técnicas de visão computacional podem ser usadas para detecção automatizada de doenças foliares, baseado no reconhecimento de padrões observáveis nas plantas, facilitando e otimizando essa tarefa. (ARIVAZHAGAN *et al.*, 2013).

Patel e Joshi (2017), conceituaram um processo básico com as principais atividades relacionadas ao uso de Visão Computacional para classificação de doenças foliares (Figura 6), que é composto pelas seguintes etapas: i) Aquisição das imagens; ii) Pré-processamento das imagens; iii) Segmentação das imagens; iv) Extração de características; e v) Classificação e detecção de doenças foliares. Cada uma dessas etapas serão descritas detalhadamente a seguir:

**Figura 6 – Etapas do uso de Visão Computacional para detecção de doenças foliares**



**Fonte: Adaptado de Patel e Joshi (2017).**

- **Aquisição da Imagem:** Patel e Joshi (2017), define que a etapa de aquisição tem como objetivo principal capturar imagens de alta qualidade das folhas de plantas através do uso de uma câmera.
- **Pré-processamento da Imagem:** o objetivo dessa etapa é melhorar a imagem para aumentar as chances de sucesso nas etapas seguintes. Geralmente envolve uso de filtros e técnicas de Processamento Digital de Imagens (GONZALEZ; WOODS, 2010).
- **Segmentação da Imagem:** divide imagem em unidades significativas, em outras palavras, identifica e separa objetos de interesse (PATEL; JOSHI, 2017). Gonzalez e Woods (2010). Para muitas imagens a atividade de segmentação pode ser complexa, porém, em contrapartida, uma boa segmentação favorece as próximas atividades do processo de classificação de padrões.
- **Extração de Características:** dados das imagens são extraídos para serem utilizados como base para a execução da atividade de classificação e detecção de doenças foliares. Pode-se destacar algumas características que podem desempenhar um papel importante para identificação de doenças foliares, tais como, cor, textura, formas e bordas (PATEL; JOSHI, 2017).
- **Classificação e detecção de doenças foliares:** algoritmos são treinados e utilizados para atribuir rótulos nas imagens com base nas características extraídas. São exemplos de métodos de aprendizado de máquina que podem ser utilizados para classificar e detectar doenças foliares: Redes Neurais (RN), Máquina de vetores de suporte (SVM, do inglês Support Vector Machine) e K-ésimo Vizinho mais Próximo (K-NN, do inglês K-Nearest Neighbors) (PATEL; JOSHI, 2017).

## 2.6 Aprendizado de Máquina

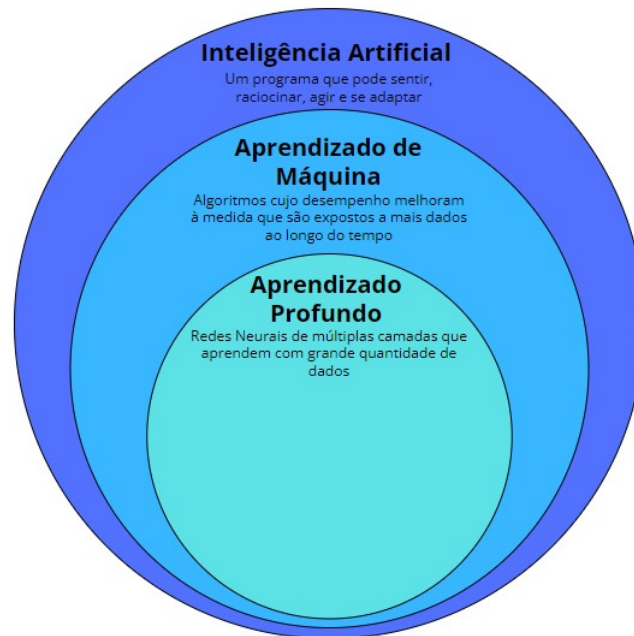
Naqa e Murphy (2015) definem que a AM, é um subcampo da IA, que pode ser definido como um processo computacional que utiliza dados de entrada para realizar uma determinada atividade sem ter que ser literalmente programado. Esses algoritmos se adaptam e se alteram automaticamente por meio da repetição, experiência e exposição a mais dados para melhorarem constantemente a aferição da performance nessa atividade.

Destaca-se que dentro da AM existe uma subcategoria chamada de Aprendizado Profundo (AP), tradução do termo em inglês, *Deep Learning*. AP é a forma mais especializada de aprendizado que permite que modelos computacionais compostos de muitas camadas de processamento aprendam a interpretar dados com vários níveis de abstração. Este modelo por meio de algoritmos de retro-propagação indicam como uma máquina precisa modificar seus parâmetros internos, os quais são utilizadas para calcular a camada atual baseado na camada anterior. Esses métodos ajudaram a atingir novos estados da arte em várias áreas, como: reconhecimento

de fala, reconhecimento de objeto visual, detecção de objeto, processamento de imagens, entre outras (LECUN; BENGIO; HINTON, 2015).

A Figura 7 ilustra a relação hierárquica entre IA, AM e AP - os dados desta Figura tem como fonte o trabalho de Enrici (2018).

**Figura 7 – Diagrama de distribuição da IA**



**Fonte: Adaptado de Enrici (2018).**

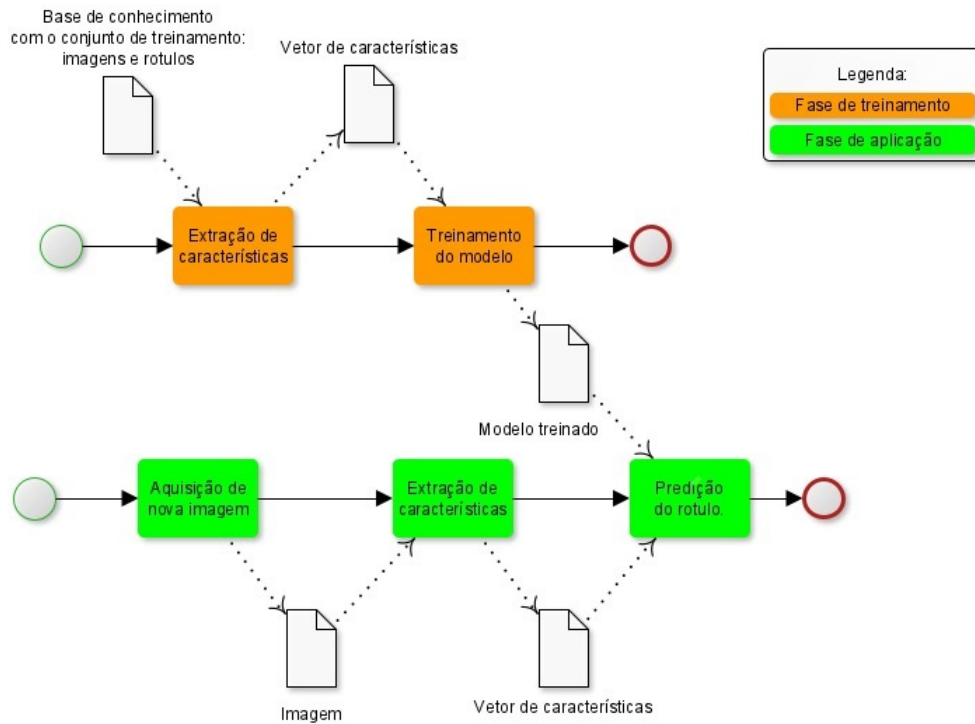
Técnicas de IA baseadas em algoritmos de AM tradicionais e/ou AP, podem (e comumente) são aplicadas como parte de métodos de Visão Computacional, na etapa de classificação e detecção de doenças foliares, conforme é apresentado na subseção 2.5.1. Mais detalhes sobre o processo de uso de algoritmos de AM são apresentados na Subseção 2.6.1.

### 2.6.1 Processo do uso de aprendizado de Máquina

No trabalho de Wäldchen *et al.* (2018) é realizado um estudo sobre a identificação de espécies de plantas usando técnicas de visão computacional. Esses autores conceituaram um processo do uso de AM para atingir esse objetivo. Destaca-se que o mesmo processo utilizada para classificação de espécies de plantas, pode ser utilizado como base para predição de doenças e folhas sudáveis. A modelagem desse processo com a Notação BPMN (*Business Process Model and Notation*) (DIJKMAN; HOFSTETTER; KOEHLER, 2011) é apresentada na Figura 8. O processo apresentado é dividido em duas fases: i) Fase de treinamento (laranja na Figura 8) e ii) Fase de aplicação (verde na Figura 8). Detalhes sobre cada uma das atividades são apresentados a seguir.

Na Fase de treinamento, a partir de uma base de conhecimento formada por uma grande quantidade de imagens rotuladas se realiza a extração das características das imagens, gerando

**Figura 8 – Etapas do treinamento do e aplicação de algoritmos de Aprendizado de Máquina para identificação de espécies de Plantas**



**Fonte: Adaptado de Wäldchen *et al.* (2018).**

um vetor de características. De acordo com Gonzalez e Woods (2010) o vetor de características busca representar a “essência” da imagem, como cor, textura, forma dos objetos e relacionamento entre esses objetos. Na sequência, com esses dados o classificador aprende a distinguir os rótulos de interesse, resultando em um modelo treinado.

Já na Fase de aplicação, acontece a aquisição de uma nova imagem, que tem suas características extraídas, resultando em um novo vetor de características que é utilizado para predição do rótulo com o modelo treinado.

### 3 METODOLOGIA

Esse Capítulo apresenta a metodologia utilizada para produzir as bases de dados e conduzir experimentos referentes a classificação automática de doenças foliares.

A Subseção 3.1 apresenta os procedimentos de coleta de dados utilizados. A etapa de validação das imagens é descrita na Subseção 3.2. O pré-processamento aplicado em cada figura selecionada é detalhado na Subseção 3.3. Os critérios para divisão da base de dados experimental nos conjuntos de treinamento e validação utilizados em cada estudo de caso são apresentados na Subseção 3.4. O processo de treinamento dos modelos de RNC é descrito na Subseção 3.5. As métricas experimentais utilizadas são descritas na Subseção 3.6.

#### 3.1 Coleta de Dados

Para coletar as imagens que compuseram a base de dados experimental, optou-se por utilizar uma abordagem similar a utilizada para produção da base de dados PlantVillage, em termos da configuração do ambiente de aquisição das imagens e tamanho da base de dados.

- **Ambiente de aquisição das imagens:** as fotos foram tiradas individualmente para cada folha, com um fundo uniforme. Nos experimentos foi utilizada uma folha de papel sulfite A4 branco como fundo para fotos; e
- **Tamanho da base de dados:** na PlantVillage, se descartando as três classes com mais de cinco mil imagens, para as demais, existe uma média de 1095 fotos, com um desvio padrão de 406 imagens.

As novas imagens coletadas para compor a base de dados experimental, foram divididas em três classes: i) Soja com míldio; ii) Lichia com ácaro; e iii) Lichia sem ácaro

Com relação a Soja, de acordo com estimativas da safra 2021/22 realizada pela CONAB (2022), problemas climáticos impactaram em perdas expressivas na produtividade da soja, principalmente nos estados da Região Sul do Brasil, devido aos índices pluviométricos que não atingiram a média da região, o que influenciou diretamente em uma quantidade menor de imagens coletadas para essa classe - conforme descrito na Subseção 2.2.1, o Míldio (entre outras doenças), para incidir nas folhas, precisa de alta umidade.

Para as classes referentes a folhas de Lichia (com e sem ácaro), não houve fatores climáticos ou de outra origem que influenciaram na coletas das imagens. Desta forma, foi possível coletar uma quantidade de imagens conforme a média de fotos por rótulo da base de dados PlantVillage.

A Tabela 1 abaixo descreve para cada rótulo, informações sobre as imagens coletadas: nome da classe, local (cidade, estado e coordenadas de latitude e longitude do local), data da coleta, dispositivo utilizado para captura e quantidade de imagens obtidas.

**Tabela 1 – Dados sobre a etapa de coletas das imagens**

| <b>Classe/Rótulo</b> | <b>Local</b>                                       | <b>Data</b> | <b>Dispositivo</b>     | <b>Imagens Coletadas*</b> |
|----------------------|--|-------------|------------------------|---------------------------|
| Soja com míldio      | Dois Vizinhos-PR<br>-25.695029, -53.094839         | 17/12/2022  | Xiaomi Redmi<br>Note 9 | 120                       |
|                      | Santa Izabel do Oeste-PR<br>-25.900766, -53.388251 | 07/01/2022  | Xiaomi Redmi<br>Note 9 | 372                       |
| Lichia com Ácaro     | Pedrinhas Paulista-SP<br>-22.807499, -50.804965    | 04/02/2022  | Samsung<br>Galax A31   | 1050                      |
| Lichia sem Ácaro     | Pedrinhas Paulista-SP<br>-22.807499, -50.804965    | 17/02/2022  | Samsung<br>Galax A31   | 1050                      |

\*: representa a quantidade total de imagens coletadas antes da etapa de validação.

**Fonte: Autoria própria.**

### 3.2 Validação das Imagens

Destaca-se que a etapa de coleta de dados foi realizada por pessoas não especialistas em Agronomia/Fitopatologia. Porém, na etapa de validação todas as imagens foram rotuladas por uma Doutora em Agronomia especializada em Fitopatologia com pesquisas recentes nessa área.

A especialista analisou cada uma das imagens e removeu as figuras para as quais ela não teve certeza que o rótulo estava correto. A Tabela 2 apresenta a quantidade de imagens coletadas e também a quantidade de fotos que foram selecionadas pela especialista para compor a base de dados experimental.

**Tabela 2 – Quantidade de imagens coletadas/selecionadas**

| <b>Classe/Rótulo</b> | <b>Imagens</b>   |                     |
|----------------------|------------------|---------------------|
|                      | <b>Coletadas</b> | <b>Selecionadas</b> |
| Soja com míldio      | 492              | 268                 |
| Lichia com Ácaro     | 1050             | 1000                |
| Lichia sem Ácaro     | 1050             | 1020                |

**Fonte: Autoria própria.**

### 3.3 Pré-processamento das Imagens

Após à conclusão das atividades de aquisição e validação das imagens, para todas as fotos selecionadas foi aplicada uma etapa de pré-processamento antes do início da etapa de treinamento dos modelos de RNC.

Para as folhas de soja e lichia, o processo de pré-processamento seguiu as mesmas duas etapas etapas (segmentação da folha e corte da área de interesse na imagem), divergindo apenas nos critérios utilizados em cada uma. As Subseções 3.3.1 e 3.3.2 descrevem os critérios utilizados para o pré-processamento das folhas de soja e lichia, respectivamente.

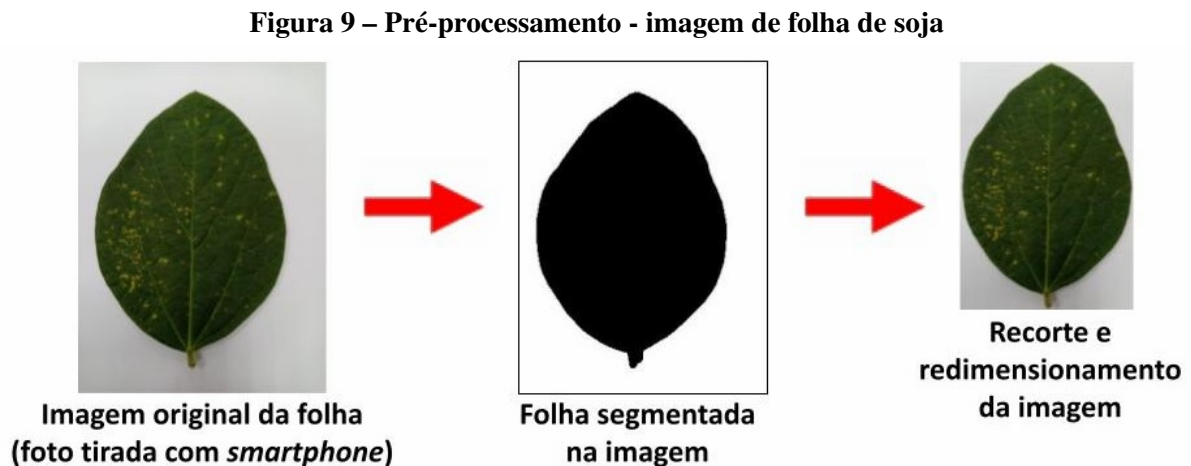
### 3.3.1 Pré-processamento - folhas de soja

Para cada foto de Soja selecionada foi criada uma cópia. Essa cópia foi convertida do sistema de cores RGB para escala de cinza.

Cada imagem em nível de cinza foi segmentada utilizando o limiar o valor 125, gerando uma imagem binária. Após a segmentação foram realizadas as operações de abertura e fechamento morfológico (SERRA, 1986), para remover eventuais falhas na segmentação.

A posição da região de interesse na imagem binária foi utilizada como parâmetro para recortar a folha de soja na imagem original (RGB) - a região desse recorte gerou uma terceira imagem que foi redimensionada e salva no tamanho padrão das imagens da base de dados PlantVillage. Essa imagem redimensionada foi utilizada para execução dos experimentos.

A foto original de uma folha de soja, o resultado da segmentação da imagem e o resultado do recorte e redimensionamento da folha original, são apresentados na Figura 9.



**Fonte: Autoria Própria.**


### 3.3.2 Pré-processamento - folhas de lichia

Cada foto de folha Lichia selecionada foi segmentada utilizando como limiar os seguintes valores RGB: R = 85; G = 100; e B = 85. Na binária resultante dessa segmentação foram aplicadas as operações de abertura e fechamento morfológico (SERRA, 1986), para remover eventuais falhas na segmentação.

A posição da região de interesse na imagem segmentada é utilizada como parâmetro para recortar a folha de Lichia na imagem original (RGB), gerando uma terceira imagem que foi redimensionada e salva no tamanho padrão das imagens da base de dados PlantVillage. Essa imagem redimensionada foi utilizada para execução dos experimentos.

A foto original da folha, o resultado da segmentação da imagem e o resultado do recorte e redimensionamento da folha original, são apresentados na Figura 10.

**Figura 10 – Pré-processamento - imagem de folha de Lichia**



Fonte: Autoria Própria.

### 3.4 Divisão da Base de Dados

A base de dados experimental utilizada nos experimentos realizados, foi composta por imagens de três conjuntos distintos: i) imagens de folhas de Soja e Lichieira coletadas para este projeto: 1000 fotos de folhas de lichia com ácaro da erinose; 1020 imagens de folhas de lichia sem o efeito desse ácaro; e 268 folhas de soja com míldio; ii) todas as imagens da PlantVillage (54305 imagens divididas em 38 classes) (HUANG *et al.*, 2017); e iii) imagens de fundo aleatório (1 classe composta por 715 imagens (GOULD; FULTON; KOLLER, 2009)

As imagens da PlantVillage, foram utilizadas para avaliar a capacidade dos modelos treinados distinguirem as novas classes de imagens de outros tipos folhas/doenças. Já as figuras com fundos aleatórios para obter uma melhor acurácia na classificação de folhas/doenças já foi explorada em outros trabalhos (SLADOJEVIC *et al.*, 2016; BRAHIMI *et al.*, 2018). Devido aos bons resultados relatados para essa abordagem, essa classe de imagens foi utilizada no estudo de caso deste trabalho.

Três subconjuntos desse conjunto de 57308 divididas em 42 classes, foram utilizadas para executar três etapas experimentais. Na primeira etapa (primeiro estudo de caso) se avaliou a capacidade das RNCs distinguirem folhas de Lichia (com e sem Ácaro) e de Soja com Míldio, de outros tipos folhas/doenças. Na segunda etapa (segundo estudo de caso) se avaliou a capacidade das RNCs identificarem ataques de Ácaro - apenas com folhas de Lichia. Na terceira etapa (terceiro estudo de caso), foi avaliada a capacidade das RNCs identificarem a presença de Míldio - apenas folhas de soja. Os conjuntos de imagens utilizados em cada etapa dos experimentos são descritas a seguir:

- Primeiro estudo de caso: todas as 57308 imagens: 2288 fotos de folhas de Soja e Lichieira coletadas para este trabalho, 54305 imagens da base PlantVillage, e 715 fotos com fundos aleatórios;
- Segundo estudo de caso: as 2020 imagens de folhas de Lichia coletadas para este projeto; e



- Terceiro estudo de caso: com 5358 imagens: 5090 folhas de soja saudáveis da PlantVillage e 268 folhas de soja com míldio coletadas para este estudo.

Para execução dos três estudos de casos, independentemente do conjunto de imagens utilizada, 80% das fotos foram utilizadas para criar o conjunto de treinamento e as demais 20% compuseram o conjunto de validação.

### 3.5 Treinamento dos modelos

Para execução dos experimentos foram selecionadas oito RNCs: i) AlexNet (KRIZHEVSKY, 2014); ii) DenseNet1169 (HUANG *et al.*, 2017); iii) EfficientNetB7 (TAN; LE, 2019); iv) InceptionV3 (SZEGEDY *et al.*, 2016); v) MobileNetV2 (HOWARD *et al.*, 2019); vi) ResNet34 (HE *et al.*, 2016); vii) SqueezeNet (IANDOLA *et al.*, 2016); e viii) VGG13 (SIMONYAN; ZISSERMAN, 2014).

Cinco dessas RNCs foram escolhidas por apresentarem resultados superiores a 99.2% para classificação das folhas da base de dados PlantVillage:

- AlexNet: 99.24% de acurácia em (BRAHIMI *et al.*, 2018);
- DenseNet169: 99.72% de acurácia em (BRAHIMI; BOUKHALFA; MOUSSAOUI, 2017);
- InceptionV3: 99.76% de acurácia em (BRAHIMI; BOUKHALFA; MOUSSAOUI, 2017);
- ResNet34: : 99.67% de acurácia em Brahim *et al.* (2018); e
- VGG13: 99.49% de acurácia em (BRAHIMI *et al.*, 2018).

As outras três RNCs foram escolhidas por serem mais recentes, e portanto, terem potencial para apresentarem melhores resultados: EfficientNetB7, MobilenetV2, e SqueezeNet.

No primeiro estudo de caso, para cada uma dessas RNCs os modelos predição foram treinados com três estratégias de treinamento distintas (ambas descritas na Subseção ??): i) ajuste fino; ii) treinamento do zero; e iii) treinamento profundo).

Já para os demais estudos de casos, foi selecionada apenas a RNC que obteve a melhor acurácia no primeiro estudo de casos, para cada uma das três estratégias de treinamento.

Destaca-se, que todos os modelos foram realizados em um computador com uma placa de vídeo GPU GTX 1080ti. O algoritmo utilizado é uma adaptação do código disponibilizado por (BRAHIMI *et al.*, 2018)<sup>1</sup>.

<sup>1</sup> [https://github.com/MarkoArsenovic/DeepLearning\\_PlantDiseases](https://github.com/MarkoArsenovic/DeepLearning_PlantDiseases)

### 3.6 Métricas Experimentais

Para avaliar os resultados experimentais obtidos para cada um dos modelos treinados, foram aplicadas as mesmas métricas experimentais exploradas em trabalhos relacionados (BRAHIMI *et al.*, 2018; APPLALANAIDU; KUMARAVELAN, 2021): acurácia (proporção de imagens classificadas corretamente) e tempo de treinamento dos modelos.


## 4 RESULTADOS EXPERIMENTAIS

As Seções de 4.1, 4.2 e 4.3 apresentam os resultados dos três estudos de caso. Uma análise desses resultados é feita na Seção 4.4

### 4.1 Resultados do Primeiro Estudo de Caso

Os resultados obtidos com o primeiro estudo de caso para classificação de 57308 fotos divididas em 42 classes são apresentados na Tabela 3. Essa tabela é composta por quatro colunas que apresentam, os seguintes dados: i) a estratégia de treinamento; e ii) a RNC utilizada; iii) a acurácia obtida; e iv) o tempo de treinamento. A acurácia obtida com cada uma das RNCs utilizadas no primeiro estudo de caso também pode ser comparada na forma de gráfico na Figura 11 - que agrupa as RNCs por estratégia de treinamento.

**Figura 11 – Gráfico da Acurácia - Primeiro Estudo de Caso**



**Fonte: Autoria Própria.**

Tabela 3 – Resultados Experimentais - Primeiro Estudo de Caso

| Estratégia           | RNC           | Acurácia      | Tempo de Treinamento |
|----------------------|---------------|---------------|----------------------|
| Ajuste Fino          | AlexNet       | 91.26%        | <b>0.53 horas</b>    |
|                      | DenseNet169*  | <b>95.69%</b> | 4.62 horas           |
|                      | EfficientNet* | 90.42%        | 1.70 horas           |
|                      | InceptionV3   | 91.43%        | 1.30 horas           |
|                      | MobileNetV2   | 93.77%        | 0.67 horas           |
|                      | ResNet34      | 94.87%        | 1.05 horas           |
|                      | SqueezeNet    | 93.17%        | 0.59 horas           |
|                      | VGG13         | 91.43%        | 1.14 horas           |
| Treinamento do Zero  | AlexNet       | 96.35%        | <b>0.68 horas</b>    |
|                      | DenseNet169*  | 97.11%        | 4.62 horas           |
|                      | EfficientNet* | 95.78%        | 10.22 horas          |
|                      | InceptionV3   | 96.54%        | 3.00 horas           |
|                      | MobileNetV2   | <b>97.79%</b> | 1.10 horas           |
|                      | ResNet34      | 96.65%        | 1.89 horas           |
|                      | SqueezeNet    | 91.51%        | 0.73 horas           |
|                      | VGG13         | 97.71%        | 2.37 horas           |
| Treinamento Profundo | AlexNet       | 98.07%        | <b>0.68 horas</b>    |
|                      | DenseNet169*  | <b>99.75%</b> | 4.59 horas           |
|                      | EfficientNet* | 99.61%        | 10.20 horas          |
|                      | InceptionV3   | 99.69%        | 2.97 horas           |
|                      | MobileNetV2   | 99.31%        | 1.09 horas           |
|                      | ResNet34      | 99.59%        | 1.92 horas           |
|                      | SqueezeNet    | 97.05%        | 0.73 horas           |
|                      | VGG13         | 99.34%        | 2.32 horas           |

\*: Por padrão o parâmetro 20 foi utilizado para o tamanho de lote (*batch size*), porém devido a quantidade de memória da GPU utilizada nos treinamentos o tamanho de lote teve que ser alterado para duas das RNCs. Para a DenseNet169 foi necessário utilizar 10 como tamanho de lote. Para a EfficientNet foi necessário utilizar 5 como tamanho de lote.

**Fonte: Autoria Própria.**

## 4.2 Resultados do Segundo Estudo de Caso

Para o segundo estudo de caso, referente a classificação de 2020 folhas de Lichia com e sem o ataque do ácaro da Erinose, foram selecionadas apenas as RNCs DenseNet169 e MobileNetV2 - que tiveram a melhor acurácia para pelo menos uma das estratégias de treinamento no primeiro estudo de caso. Neste estudo de caso, para o treinamento de ambas as RNCs foi utilizado o tamanho de lote igual a 20.


Os resultados do segundo estudo caso são apresentados na Tabela 4, que possui a mesma estrutura da Tabela 3. A Figura 12 apresenta um gráfico que compara acurácia obtida com cada RNC no segundo estudo de caso.

**Tabela 4 – Resultados Experimentais - Segundo Estudo de Caso**

| Estratégia           | RNC         | Acurácia | Tempo de Treinamento |
|----------------------|-------------|----------|----------------------|
| Ajuste Fino          | DenseNet169 | 94.80%   | <b>0.04 horas</b>    |
| Treinamento do Zero  | MobileNetV2 | 86.14%   | <b>0.04 horas</b>    |
| Treinamento Profundo | DenseNet169 | 90.35%   | 0.16 horas           |

**Fonte: Autoria Própria.**

**Figura 12 – Gráfico da Acurácia - Segundo Estudo de Caso**



**Fonte: Autoria Própria.**

### 4.3 Resultados do Terceiro Estudo de Caso

Para o terceiro estudo de caso, referente a classificação de 5358 folhas de Soja sádias e com ataque de ácaro, também foram selecionadas apenas as RNCs DenseNet169 e MobileNetV2 - que tiveram a melhor acurácia para pelo menos uma das estratégias de treinamento no primeiro estudo de caso. Neste estudo de caso, para o treinamento de ambas as RNCs foi possível utilizar o tamanho de lote igual a 20.


Os resultados do terceiro estudo caso são apresentados na Tabela 5, que possui a mesma estrutura das Tabelas 3 e 4. A Figura 13 apresenta um gráfico que compara a acurácia obtida com cada RNC no terceiro estudo de caso.

**Tabela 5 – Resultados Experimentais - Terceiro Estudo de Caso**

| <b>Estratégia</b>    | <b>RNC</b>  | <b>Acurácia</b> | <b>Tempo de Treinamento</b> |
|----------------------|-------------|-----------------|-----------------------------|
| Ajuste Fino          | DenseNet169 | <b>100%</b>     | 0.11 horas                  |
| Treinamento do Zero  | MobileNetV2 | 99.91%          | <b>0.10 horas</b>           |
| Treinamento Profundo | DenseNet169 | <b>100%</b>     | 0.44 horas                  |

**Fonte: Autoria Própria.**

**Figura 13 – Gráfico da Acurácia - Terceiro Estudo de Caso**



**Fonte: Autoria Própria.**

#### 4.4 Análise dos Resultados

Com o primeiro estudo de caso, que considerou um conjunto de 57308 imagens divididas em 42 classes, se obteve na melhor instância experimental uma acurácia de 99.75% com a RNC DenseNet169 (e a estratégia de treinamento profundo), que é apenas 0.01% inferior a melhor acurácia apresentada em (BRAHIMI *et al.*, 2018) e 0.04% inferior a melhor acurácia apresentada em (APPLALANAIDU; KUMARAVELAN, 2021). Isso indica que os resultados obtidos para este estudo de caso estão muito próximos ao estado da arte da base de dados PlantVillage.

Para as demais estratégias de treinamento aplicadas no primeiro estudo de caso, as melhores acurácias obtidas foram de 95.69% (para o ajuste fino) e 97.79% (para o treinamento do zero). Considerando essas estratégias de treinamento, o resultado do primeiro estudo de caso está mais distante dos apresentados em (BRAHIMI *et al.*, 2018) (diferença próxima a 1%). Novos experimentos podem ser feitos com outras RNCs visando melhorar os resultados obtidos com essas estratégias de treinamento, mas deve-se destacar que o melhor resultado obtido com a estratégia de treinamento profundo, no primeiro estudo de caso, está extremamente próxima dos resultados no estado da arte para a PlantVillage.

Quanto a acurácia do segundo estudo de caso (2020 folhas de Lichia com e sem ataque de ácaro), o melhor resultado foi de 94.80%, obtido com a RNC DenseNet169 e a estratégia de treinamento ajuste fino. Para a classificação desse tipo de folhas acredita-se que novos experimentos devem ser realizados visando obter uma acurácia similar (ou superior) a obtido no primeiro estudo caso, para tal, pode-se em trabalhos futuros: expandir o tamanho da base de dados, executar experimentos com outras técnicas de AM e AP, além de se explorar o verso das folhas de Lichia (no qual, características do ataque do ácaro também se manifestam).

Quanto ao terceiro estudo de caso, chegou-se a uma acurácia de 100%, essa é a melhor acurácia de todos os trabalhos analisados, o que é positivo, mas pode indicar um problema na base de dados experimental utilizada: características e posicionamento dos equipamentos utilizados para aquisição de fotos neste trabalho e na base PlantVillage, podem ter influência nos resultados de classificação. Essa hipótese deve ser validada em trabalhos futuros.

Destaca-se que a quantidade baixa de fotos de Soja coletadas para este estudo, se justifica pelos baixos índices pluviométricos na região de Dois Vizinhos no período de realização deste Trabalho de Conclusão de Curso, fato esse que pode ter impactado na confiabilidade dos resultados experimentais obtidos para esse tipo de folha.

Quanto ao tempo de execução dos experimentos, é difícil fazer uma análise comparado diretamente o tempo de treinamento da DenseNet169 (que obteve as melhores acurácias) com o tempo de treinamento das outras RNCs, pois nos últimos estudos de casos se utilizou apenas uma RNC para cada estratégia de treinamento e no primeiro estudo de caso teve-se que aplicar um tamanho de lote menor para o treinamento da DenseNet169. Porém, mesmo sem uma análise

precisa do tempo de treinamento das RNCs, a diferença em termos de acurácia justifica a escolha de modelos treinados com a DenseNet169.



## 5 CONSIDERAÇÕES FINAIS

O uso de Visão Computacional para classificação automática de doenças foliares pode contribuir para agilizar a sua identificação, o que possibilita diminuir o tempo necessário para que as primeiras ações sejam postas em prática, reduzir custos com uso de agrotóxicos e outros recursos, e auxiliar nas tomadas de decisões. Consequentemente, esses fatores amenizam o dano causado pelas enfermidades, aumentando a produção agrícola.

Neste contexto, o trabalho proposto apresentou duas contribuições para a literatura, que são referentes aos objetivos específicos planejados:

- Contribuição 1: produção de uma nova base de dados com fotos de folha de Lichia (com e sem as injúrias provocadas pelo Ácaro da Erinose) e de Soja com Míldio. Em futuros artigos (consequentes deste trabalho) essa base de dados será disponibilizada publicamente.
- Contribuição 2: estudos de casos conduzido para avaliar a capacidade de RNCs rotularem corretamente imagens de folhas com as classes da base de dados produzida para este projeto. Foi possível obter modelos que alcançaram uma acurácia de 99.75%, para detecção das novas classes em conjunto com outras 39 classes de folhas. Exclusivamente para folhas de Lichia, a acurácia obtida foi de 94.80%, já para folhas de soja a acurácia foi de 100% - essa taxa de acerto máximo ser decorrente de problemas na base de dados, o que deve ser validado com outros experimentos.

Com base na análise dos resultados experimentais, apresentada na Seção 4.4, é possível identificar possibilidades de trabalhos futuros que podem contribuir para melhorar os resultados deste trabalho:

- Estender as bases de dados existentes visando melhorar os resultados de classificação atuais e/ou validar possíveis problemas, como no caso da classificação de folhas de soja (terceiro estudo de caso deste trabalho).
- Realizar experimentos com outros algoritmos ou técnicas de AM e DL afim de verificar se irá ocorrer aumento na acurácia.

Além destas sugestões de trabalhos que são diretamente relacionadas aos experimentos deste trabalho, também pode-se pensar em trabalhos futuros que contribuam no contexto da classificação e análise automática de doenças foliares:

- Criar novas bases de dados com imagens de doenças e/ou plantas não contempladas nas bases apresentadas.

- Segmentar a região das folhas afetada pelas doenças e classificar a intensidade do ataque de cada uma delas, o que pode produzir informações relevantes para os profissionais da área.
- Desenvolvimento de uma Interface de Programação de Aplicações (em inglês, Application Programming Interface - API) para disponibilizar acesso aos modelos de classificação treinados, com intuito de fomentar a criação de plataformas ou aplicativos para predição de doenças foliares.
- Criar estratégias colaborativas para produção de bases de dados de doenças foliares, que permitam que próprios profissionais dessa área coatribuam diretamente na coleta dessas imagens.

## REFERÊNCIAS

- ALEXANDRATOS, N.; BRUINSMA, J. World agriculture towards 2030/2050: the 2012 revision. 2012.
- APPLALANAIDU, M. V.; KUMARAVELAN, G. A review of machine learning approaches in plant leaf disease detection and classification. *In: IEEE. International Conference on Intelligent Communication Technologies and Virtual Mobile Networks*. [S.l.], 2021. p. 716–724.
- ARIVAZHAGAN, S. *et al.* Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. **Agricultural Engineering International: CIGR Journal**, v. 15, n. 1, p. 211–217, 2013.
- BARBEDO, J. G. A.; MEIRA, C. A. A. Tic na segurança fitossanitária das cadeias produtivas. **Embrapa Informática Agropecuária**, 2014.
- BRAHIMI, M. *et al.* Deep learning for plant diseases: detection and saliency map visualisation. *In: Human and machine learning*. [S.l.]: Springer, 2018. p. 93–117.
- BRAHIMI, M.; BOUKHALFA, K.; MOUSSAOUI, A. Deep learning for tomato diseases: classification and symptoms visualization. **Applied Artificial Intelligence**, Taylor & Francis, v. 31, n. 4, p. 299–315, 2017.
- COLELLA, J. C. T. Uso da visão computacional para medição de crescimento fúngico. Universidade Estadual de Maringá, 2012.
- CONAB. **12º Levantamento - Safra 2020/21**. 2021. Disponível em: <https://www.conab.gov.br/info-agro/safra/safra-graos/boletim-da-safra-de-graos/item/download/3903587337ecd3ff2f149c03db5d05735bcd1>.
- CONAB. **Nova estimativa aponta para uma produção de grãos na safra 2021/22 em 268,2 milhões de toneladas**. 2022. Disponível em: <https://www.conab.gov.br/ultimas-noticias/4494-nova-estimativa-aponta-para-uma-producao-de-graos-na-safra-2021-22-em-268-2-milhoes-de-toneladas>.
- CROSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. [S.l.]: UNICAMP/Instituto de Geociências, 1999.
- DEUS, G. A. M. de. **Descritores de textura local para identificação de fungos em folhas de soja**. 2018. Dissertação (Mestrado) — Modelagem e Otimização - Universidade Federal de Goiás, Catalão, 2018.
- DIJKMAN, R.; HOFSTETTER, J.; KOEHLER, J. **Business Process Model and Notation**. [S.l.]: Springer, 2011. v. 89.
- ENRICI, J. P. Fito diagnose digital: detecção de doenças de plantas via imagens digitais. Niterói, 2018.
- FIGUEIRA, S. R. F.; GALACHE, V. d. O. Análise comparativa da competitividade das exportações de soja em grão do Brasil, Estados Unidos e Argentina. **Revista de Economia e Sociologia Rural**, SciELO Brasil, v. 61, 2022.

- FILHO, S. S. B. **Pulverização de plantas daninhas em tempo real utilizando visão computacional**. 2018. Engenharia Agrícola e Ambiental - Universidade Federal de Mato Grosso, Rondonópolis.
- GLOBO. **Ácaro da lichia preocupa produtores**. 2018.  
<https://g1.globo.com/economia/agronegocios/globo-rural/noticia/2018/03/acaro-da-lichia-preocupa-produtores.html>.
- GOMES, D. d. S. Inteligência artificial: conceitos e aplicações. **Olhar Científico**. v1, n. 2, p. 234–246, 2010.
- GONZALEZ, R. C.; WOODS, R. E. Processamento digital de imagem. **Pearson, ISBN-10: 8576054019**, v. 10, p. 11–27, 2010.
- GOULD, S.; FULTON, R.; KOLLER, D. Decomposing a scene into geometric and semantically consistent regions. *In: IEEE. IEEE International conference on computer vision*. [S.l.], 2009. p. 1–8.
- HE, K. *et al.* Deep residual learning for image recognition. *In: IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.
- HIRAKURI, M. H.; LAZZAROTTO, J. J. O agronegócio da soja nos contextos mundial e brasileiro. **Embrapa Soja-Documentos (INFOTECA-E)**, Londrina: Embrapa Soja, 2014., 2014.
- HOFFMANN-CAMPO, C. B. *et al.* **Pragas da soja no Brasil e seu manejo integrado**. [S.l.]: Embrapa, 2000. v. 30.
- HOWARD, A. *et al.* Searching for mobilenetv3. *In: IEEE/CVF International Conference on Computer Vision*. [S.l.: s.n.], 2019. p. 1314–1324.
- HUANG, G. *et al.* Densely connected convolutional networks. *In: IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708.
- HUGHES, D.; SALATHÉ, M. *et al.* An open access repository of images on plant health to enable the development of mobile disease diagnostics. **arXiv preprint arXiv:1511.08060**, 2015.
- IANDOLA, F. N. *et al.* Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model size. **arXiv preprint arXiv:1602.07360**, 2016.
- KOWATA, L. S. *et al.* Escala diagramática para avaliar severidade de míldio na soja. 2008.
- KRIZHEVSKY, A. One weird trick for parallelizing convolutional neural networks. **arXiv preprint arXiv:1404.5997**, 2014.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LOPES, C. A.; ÁVILA, A. de. Doenças do tomateiro. **Embrapa Hortaliças**, Brasília, DF: Embrapa Hortaliças, 2005.
- LU, J.; TAN, L.; JIANG, H. Review on convolutional neural network (cnn) applied to plant leaf disease classification. **Agriculture**, Multidisciplinary Digital Publishing Institute, v. 11, n. 8, p. 707, 2021.

- MACEDO, S. O. de. **Desenvolvimento de um sistema de auxílio ao diagnóstico de pneumonia na infância utilizando visão computacional**. 2012. Dissertação (Mestrado) — Computação - Universidade Federal de Goiás, Goiânia, 2012.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, p. 125–160, 2009.
- Marques Filho, O.; Vieira Neto, H. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.
- NAQA, I. E.; MURPHY, M. J. What is machine learning? *In: Machine learning in radiation oncology*. [S.l.]: Springer, 2015. p. 3–11.
- NEVES, L. A. P.; NETO, H. V.; GONZAGA, A. Avanços em visão computacional. **Curitiba: Omnipax**, p. 27, 2012.
- NORVIG, P.; RUSSELL, S. Inteligência artificial. **Editora Campus**, v. 20, 2004.
- PATEL, A.; JOSHI, B. A survey on the plant leaf disease detection techniques. **International Journal of Advanced Research in Computer and Communication Engineering**, v. 6, n. 1, 2017.
- PICOLI, P. R. F. *et al.* Ácaros predadores associados ao ácaro-da-erinoze da lichia. **Pesquisa Agropecuária Brasileira**, SciELO Brasil, v. 45, p. 1246–1252, 2010.
- QUILES, M. G.; ROMERO, R. A. F. Um sistema de visão computacional baseado em cores aplicado ao controle de um robô móvel. *In: Congresso Brasileiro de Computação*. [S.l.: s.n.], 2004. p. 379–383.
- RAMOS, A. Fisiologia da visão. **Um Estudo Sobre o “Ver” e o “Enxergar”. Análise do Simbólico no Discurso Visual**, PUC (Universidade Católica do Rio de Janeiro), Brazil, 2006.
- SANTOS, K. P. dos *et al.* Cultivo de lichia. **Revista Agronomia Brasil**, Universidade Estadual Paulista, v. 5, 2021.
- SERRA, J. Introduction to mathematical morphology. **Computer vision, graphics, and image processing**, Academic press, v. 35, n. 3, p. 283–305, 1986.
- SHINZATO, P. Y. **Sistema de identificação de superfícies navegáveis baseado em visão computacional e redes neurais artificiais**. 2010. Dissertação (Mestrado) — Ciência da Computação e Matemática Computacional - Universidade de São Paulo, São Carlos, 2010.
- SIDDIQUI, S. Lychee production in bangladesh. **Lychee Production in the Asia-Pacific Region. Food and Agricultural Organization of the United Nations, Bangkok, Thailand**, p. 28–40, 2002.
- SILVA, O. C. da *et al.* Damage to soybean caused by downy mildew. **Ciencia Rural**, Universidade Federal de Santa Maria, v. 46, n. 3, p. 389–392, 2016.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- SLADOJEVIC, S. *et al.* Deep neural networks based recognition of plant diseases by leaf image classification. **Computational intelligence and neuroscience**, Hindawi, v. 2016, 2016.
- SZEGEDY, C. *et al.* Rethinking the inception architecture for computer vision. *In: IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 2818–2826.

TAN, M.; LE, Q. Efficientnet: Rethinking model scaling for convolutional neural networks. *In*: PMLR. **International conference on machine learning**. [S.l.], 2019. p. 6105–6114.

WÄLDCHEN, J. *et al.* Automated plant species identification—trends and future directions. **PLoS computational biology**, Public Library of Science San Francisco, CA USA, v. 14, n. 4, p. e1005993, 2018.