

**UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"**  
FACULDADE DE CIÊNCIAS - CAMPUS BAURU  
DEPARTAMENTO DE COMPUTAÇÃO  
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

PEDRO VITOR JHUM HARAMOTO

**SISTEMA DE RECONHECIMENTO DE DOENÇAS EM PLANTAS**

BAURU  
Julho de 2020

PEDRO VITOR JHUM HARAMOTO

## **SISTEMA DE RECONHECIMENTO DE DOENÇAS EM PLANTAS**

Trabalho de Conclusão de Curso do Curso  
de Bacharelado em Ciência da Computação  
da Universidade Estadual Paulista “Júlio  
de Mesquita Filho”, Faculdade de Ciências,  
Campus Bauru.

Orientador: Prof<sup>a</sup>. Dr<sup>a</sup>. Simone das Graças  
Domingues Prado

BAURU  
Julho de 2020

Pedro Vitor Jhum Haramoto

## **SISTEMA DE RECONHECIMENTO DE DOENÇAS EM PLANTAS**

Trabalho de Conclusão de Curso do Curso de Bacharelado em Ciência da Computação da Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Campus Bauru.

Banca Examinadora

**Prof<sup>a</sup>. Dr<sup>a</sup>. Simone das Graças Domingues Prado**  
Orientadora  
Departamento de Computação  
Faculdade de Ciências  
Universidade Estadual Paulista "Júlio de Mesquita Filho"

**Prof. Dr<sup>a</sup>. Andréa Carla Gonçalves Vianna**  
Departamento de Computação  
Faculdade de Ciências  
Universidade Estadual Paulista "Júlio de Mesquita Filho"

**Prof. Dr. Kelton Augusto Pontara da Costa**  
Departamento de Computação  
Faculdade de Ciências  
Universidade Estadual Paulista "Júlio de Mesquita Filho"

Bauru, 01 de julho de 2020.

# Agradecimentos

Agradeço, primeiramente, à minha mãe, Lucilena, a meu avô Manoel e à minha avó Liliana, a meu padrasto Antonio e a meu irmão Arthur que sempre me apoiaram e me deram todo o amor para que eu pudesse alcançar todos os meus sonhos.

Agradeço às amizades que fiz antes dessa jornada. Há 15 anos vocês entraram e marcaram a minha vida de maneira única e que, com palavras, é impossível agradecê-los pelos momentos únicos e insubstituíveis. Obrigado Flávio, João Paulo, João Pedro Crepaldi, João Pedro Sesto, Letícia, Matheus e Thales.

Agradeço, também, à todas amizades que fiz durante essa caminhada. Agradeço ao Kawe, Raimundo, Rodney, Vicente e Vitor que, além dos conteúdos da faculdade, ensinaram-me valores que carregarei para sempre. Obrigado por fazerem parte dessa jornada que, certamente, tornou-se leve ao lado de pessoas incríveis.

Por fim, agradeço à Unesp e a todos os professores pelos ensinamentos.

*“São tempos como esses que você aprende a viver de novo”*  
*(Foo Fighters, tradução nossa)*

# Resumo

A agricultura é de extrema importância para a sociedade, dado que é através de suas técnicas que são cultivados os alimentos, indispensáveis para a sobrevivência humana. Apesar disso, muitas adversidades podem dificultar suas tarefas. Dentre elas, cabe citar as diversas doenças que as plantas podem adquirir que, muitas vezes, podem comprometer safras inteiras. Normalmente avaliadas visualmente por especialistas, a análise das doenças por humanos é algo trabalhoso e, até certo ponto, inconsistente. Uma forma de melhorar esse processo é através do uso de sistemas computacionais para reconhecimento automático das doenças. Nesse sentido, esse trabalho visa a aplicação de técnicas de reconhecimento de padrões e visão computacional através de redes neurais convolucionais para a classificação de folhas dentre saudáveis ou doentes, considerando cinco doenças diferentes em folhas de tomates. Além da construção de uma arquitetura de aprendizado profundo para fazer o reconhecimento, foi avaliada também a diferença na eficiência do sistema quando usadas imagens monocromáticas e coloridas. Foi obtida acurácia no conjunto de testes de aproximadamente 83,2% para o sistema monocromático e 95,6% para o colorido, evidenciando a superioridade deste último para este problema.

**Palavras-chave:** doenças em plantas, reconhecimento de padrões, redes neurais convolucionais.

# Abstract

Agriculture is extremely important for society, given that it is through its techniques that food, indispensable for human survival, is grown. However, many adversities can hamper your tasks. Among them, it is worth mentioning the various diseases that plants can acquire that, many times, can compromise entire harvests. Usually assessed visually by specialists, the analysis of diseases by humans is laborious and, sometimes, inconsistent. One way to improve this process is through the use of computer systems for automatic recognition of diseases. In this sense, this work aims to apply pattern recognition techniques and computer vision through convolutional neural networks to classify leaves among healthy or sick, considering five different diseases in tomato leaves. In addition to building a deep learning architecture for the recognition, the difference in system efficiency when using monochrome and color images was also evaluated. The accuracy obtained in the test set was approximately 86,9% for the monochromatic system and 96,4% for the color system, showing the superiority of the latter for this problem.

**Keywords:** plant diseases, pattern recognition, convolutional neural networks.

# Listas de figuras

Figura 1 – Diagrama esquemático do ciclo de um projeto de reconhecimento de padrões	15
Figura 2 – Rede direta com camada única não cíclica	17
Figura 3 – Rede direta com múltiplas camadas não cíclica	18
Figura 4 – Exemplificação de uma camada convolucional	19
Figura 5 – Processo de <i>pooling</i> máximo e média.	19
Figura 6 – Sequência utilizada no desenvolvimento do classificador	21
Figura 7 – Amostras das classes do conjunto de dados	22
Figura 8 – Representação do modelo construído	23
Figura 9 – Evolução da acurácia e <i>loss</i> durante o treinamento usando imagens coloridas	25
Figura 10 – Matriz de confusão do treinamento com imagens coloridas	26
Figura 11 – Evolução da acurácia e <i>loss</i> durante o treinamento usando imagens monocromáticas	26
Figura 12 – Matriz de confusão do treinamento com imagens monocromáticas	27

# **Lista de quadros**

Quadro 1 – Acurácia de classificadores para classificação de doenças em plantas . . . 13

# Lista de abreviaturas e siglas

2D	Duas dimensões
CNN	Rede Neural Convolucional
GB	<i>Gigabyte</i>
GPS	Sistema de Posicionamento Global
HSV	<i>Hue-Saturation-Value</i>
KNN	K vizinhos mais próximos
RAM	<i>Random Access Memory</i>
ReLU	<i>Rectified linear function</i>
RGB	<i>Red-Green-Blue</i>
RNA	Rede Neural Artificial
SVM	Máquinas de Vetores de Suporte
TIC	Tecnologias da Informação e Comunicação

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>1.1</b>	<b>Trabalhos Correlatos</b>	<b>12</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>14</b>
<b>2.1</b>	<b>Doenças de Plantas</b>	<b>14</b>
<b>2.2</b>	<b>Reconhecimento de Padrões</b>	<b>14</b>
<b>2.3</b>	<b>Aprendizado de Máquina</b>	<b>15</b>
<b>2.4</b>	<b>Redes Neurais Artificiais</b>	<b>16</b>
<b>2.4.1</b>	Redes Diretas com Camada Única	16
<b>2.4.2</b>	Redes Diretas com Múltiplas Camadas	17
<b>2.5</b>	<b>Aprendizado Profundo</b>	<b>17</b>
<b>2.5.1</b>	Redes Convolucionais	17
<b>2.5.1.1</b>	<i>Camada Convolucional</i>	18
<b>2.5.1.2</b>	<i>Pooling</i>	18
<b>2.6</b>	<b>Processamento de Imagem</b>	<b>19</b>
<b>3</b>	<b>DESENVOLVIMENTO</b>	<b>21</b>
<b>3.1</b>	<b>Conjunto de Dados</b>	<b>21</b>
<b>3.2</b>	<b>Pré-processamento</b>	<b>22</b>
<b>3.3</b>	<b>Aprendizado de Máquina</b>	<b>23</b>
<b>3.3.1</b>	Conv2D	23
<b>3.3.2</b>	<i>MaxPooling2D</i>	23
<b>3.3.3</b>	<i>Flatten</i>	24
<b>3.3.4</b>	<i>Dropout</i>	24
<b>3.3.5</b>	<i>Dense</i>	24
<b>3.4</b>	<b>Avaliação dos Resultados do Treinamento</b>	<b>24</b>
<b>3.4.1</b>	Abordagem RGB	24
<b>3.4.2</b>	Abordagem em Escalas de Cinza	25
<b>4</b>	<b>CONCLUSÃO</b>	<b>28</b>
	<b>REFERÊNCIAS</b>	<b>29</b>

# 1 Introdução

Agricultura é, por definição, a arte de cultivar a terra utilizando um conjunto de práticas que visam preparar o solo para a produção de vegetais e a criação de animais úteis e necessários ao homem (MICHAELIS, 2015). No Brasil, a agricultura foi beneficiada por políticas governamentais e seguiu, a partir da década de 1960, o caminho da produção em larga escala, impulsionada pela mecanização agrícola, além do uso de insumos modernos (ANGHINONI et al., 2018). Um caminho natural do desenvolvimento da agricultura é a agricultura de precisão.

A agricultura de precisão é um sistema de gestão que leva em conta a variabilidade espacial do campo com o objetivo de obter um resultado sustentável social, econômico e ambiental (BERNARDI et al., 2014). No Brasil, o setor acadêmico iniciou as atividades em agricultura de precisão em 1996, no primeiro simpósio em agricultura de precisão (BALASTREIRE, 2000). Bernardi (2014) destaca, ainda, que neste primeiro momento, o grande desafio da agricultura de precisão no Brasil era dominar a automação com auxílio de sistema de posicionamento global (GPS), levando cerca de 10 anos para que a eletrônica embarcada pudesse se tornar realidade no mercado de máquinas agrícolas, destacando, também, o surgimento de tecnologias da informação e comunicação (TIC) no setor agrícola.

Um problema importante do setor agrícola refere-se às doenças em plantas. De acordo com Sannakki (2011), doença em planta é uma deterioração do estado normal da mesma. A fitopatologia ou patologia das plantas é o estudo científico de doenças de plantas sendo que, dentro dos estudos da fitopatologia, encontram-se, dentre outros tópicos, a identificação, etiologia, ciclo e impacto econômico da doença. (SANNAKKI et al., 2011).

Um dos objetos de estudo da fitopatologia, as lesões em folhas são normalmente avaliadas visualmente por especialistas sendo, assim, um trabalho difícil que consome tempo e, até certo ponto, inconsistente (BOCK et al., 2010). Por conta disso, maneiras de melhorar esse processo são continuamente buscadas na agricultura. Uma dessas maneiras é através do reconhecimento de padrões usando computadores.

O reconhecimento de padrões, na computação, preocupa-se com a descoberta de padrões nos dados através de algoritmos, a fim de executar ações como classificar os dados em diferentes categorias (BISHOP, 2006). Uma área correlata é a visão computacional.

Visão computacional, do ponto de vista biológico, tem como objetivo desenvolver modelos computacionais que simulem o sistema visual humano. Por outro lado, o ponto de vista da engenharia objetiva construir sistemas autônomos capazes de realizar algumas tarefas do sistema visual humano (HUANG, 1996).

Neste contexto, é possível reconhecer padrões de doenças em folhas de plantas e,

através de sistemas de visão computacional, elaborar uma solução para distinguir plantas saudáveis de doentes.

## 1.1 Trabalhos Correlatos

Na literatura existem vários trabalhos relacionados à agricultura de precisão, especificamente sobre visão computacional e aprendizado de máquina. A seguir, os trabalhos que impulsionaram a classificação de doenças em plantas por meio de imagens.

Em [Mohanty, Hughes e Salathé \(2016\)](#) os autores utilizaram redes neurais artificiais para o reconhecimento de doenças. Para tal, foi analisado um conjunto de dados público contendo mais de 54.000 imagens de plantas saudáveis e doentes. Os autores treinaram uma rede neural convolucional a fim de identificar 14 culturas e 26 doenças (ou ausência delas), atingindo uma acurácia de 99,35% em um conjunto de teste extraído da mesma fonte do conjunto de dados.

O artigo de [Toda e Okura \(2019\)](#) mostra que redes neurais são capazes de capturar cores e texturas de lesões específicas de cada doença, além de indicar um diagnóstico assemelhando-se, assim, com a tomada de decisão humana. Este artigo mostra também como é possível reduzir em até 75% a quantidade de parâmetros sem afetar a acurácia da classificação.

Em [Sladojevic et al. \(2016\)](#) é mostrado o desenvolvimento de um modelo assim como uma implementação fácil e rápida utilizando redes neurais convolucionais para uso na prática. O modelo desenvolvido neste artigo é capaz de reconhecer 13 tipos de doenças, sendo que o mesmo atingiu uma precisão entre 93% e 98%. O conjunto de dados deste artigo teve como base pesquisas em diversos sites, ou seja, não é usado apenas um conjunto de dados fechado.

Já [Sardogan, Tuncer e Ozen \(2018\)](#) mostram como é possível detectar, através de métodos automáticos de classificação, 4 sintomas de doenças em tomates a partir de 500 imagens. Este artigo utiliza redes neurais convolucionais e filtros baseados em imagens coloridas (do inglês *red-green-blue* ou apenas RGB).

Por fim, em [Sharma, Hans e Gupta \(2020\)](#) foi realizada uma coleta de dados em bases como GitHub e Kaggle de plantas saudáveis e doentes de culturas como maçã, batata, tomate, uva, morango e milho. O processamento de imagens feito neste trabalho consiste em diminuir o tamanho das imagens a fim de aumentar a velocidade de processamento, além de remover ruídos indesejáveis nas imagens e, como último tratamento, a conversão do formato RGB para o formato HSV (*hue-saturation-value*) que possibilita a separação das imagens por intensidade de cor. Este trabalho mostra um processo de segmentação a fim de separar a planta do fundo da imagem. O estudo comparou quatro tipos de classificadores, a Regressão Logística, K vizinhos mais próximos (KNN), Máquinas de Vetores de Suporte (SVM) e Redes Neurais Convolucionais (CNN). Os resultados são mostrados no [Quadro 1](#).

Quadro 1 – Acurácia de classificadores para classificação de doenças em plantas

Classificador	Acurácia (%)
Regressão Logística	66,4
KNN	54,5
SVM	53,4
CNN	98,0

Fonte: [Sharma, Hans e Gupta \(2020\)](#)

O restante do trabalho está organizado como segue. Primeiramente, no [Capítulo 2](#) são introduzidos alguns conceitos fundamentais que norteiam este trabalho. Já o [Capítulo 3](#) aprofunda-se no processo do desenvolvimento do classificador construído e as ferramentas utilizadas. Por fim, o [Capítulo 4](#) apresenta as conclusões do autor sobre o trabalho desenvolvido.

## 2 Fundamentação Teórica

Este capítulo abordará os assuntos estudados para a realização deste trabalho. Antes de prosseguir, cabe definir brevemente alguns conceitos.

### 2.1 Doenças de Plantas

Admite-se que uma planta é saudável, ou normal, quando a mesma é capaz de executar suas funções fisiológicas, ou seja, se é capaz de realizar processos como absorver água e nutrientes do solo, realizar fotossíntese, produzir sementes, dentre outros. Portanto, quando a planta não apresenta uma ou mais dessas funções essenciais por interferência de um patógeno, é considerada uma planta doente ([AGRIOS, 2005](#)).

O termo fitopatologia, derivado das palavras gregas *Phyton* (planta), *Pathos* (doença) e *Logos* (estudo), é conhecido como a ciência que estuda a interação entre planta, doença e meio ambiente, além de estabelecer a prevenção e controle. Sendo assim, a fitopatologia abrange a diagnose, sintomatologia, etiologia, epidemiologia e até mesmo o controle das doenças ([CAROLLO; FILHO, 2016](#)).

Um diagnóstico tem como objetivo encontrar respostas para um conjunto de informações ou sintomas ([PENG; REGGIA, 1990](#)), através de observações na planta e distribuição dos sintomas. A fim de agilizar o processo de diagnóstico de uma doença em planta, é possível utilizar visão computacional e análise de imagens, dado que tais ferramentas são capazes de coletar e processar grandes volumes de dados de maneira não invasiva e não destrutiva ([SANTOS; YASSITEPE, 2014](#)).

### 2.2 Reconhecimento de Padrões

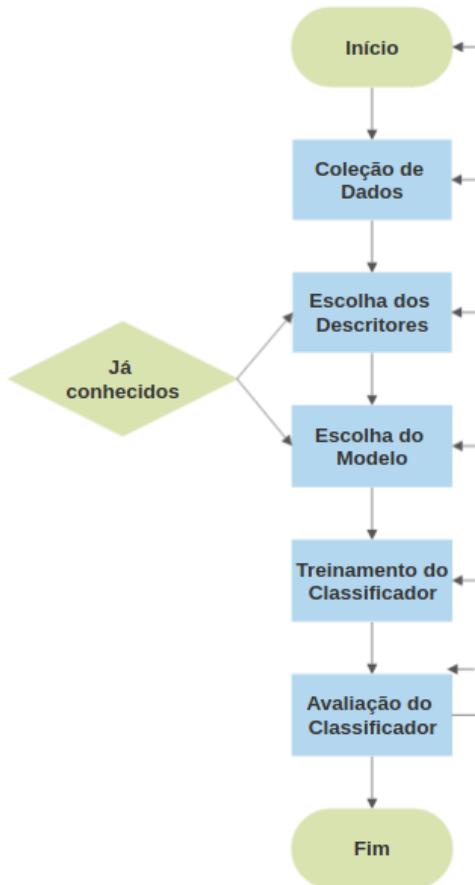
Reconhecimento de padrões é o estudo de como máquinas observam o ambiente, classificando os padrões de interesse, além de tomar decisões relacionadas à categoria do problema em questão ([JAIN; DUIN; MAO, 2000](#)).

“A facilidade com que reconhecemos um rosto, entendemos as palavras faladas, lemos caracteres manuscritos, identificamos as chaves de carro no bolso pelo tato e decidimos se uma maçã está madura por seu cheiro, mostra os processos surpreendentemente complexos subjacentes a esses atos de reconhecimento de padrões. O reconhecimento de padrões - o ato de coletar dados brutos e realizar uma ação com base na "categoria" do padrão - foi crucial para nossa sobrevivência e, nos últimos dez milhões de anos, desenvolvemos sistemas neurais e cognitivos altamente sofisticados para tais tarefas.” ([DUDA; HART; STORK, 2000](#), tradução nossa).

O leque de aplicações para o reconhecimento de padrões é grande, é possível aplicá-lo em, por exemplo, exames médicos, mercado financeiro, música e, no caso deste trabalho, na detecção de doenças de plantas.

O ciclo de projeto de um sistema de reconhecimento de padrões é feito, inicialmente, através da coleta de dados, escolha dos descritores e modelo, treinamento do classificador e, por fim, a análise do classificador é realizada como mostra a [Figura 1](#).

Figura 1 – Diagrama esquemático do ciclo de um projeto de reconhecimento de padrões



Fonte: Elaborada pelo autor

De todas as abordagens de reconhecimento de padrões, as quatro mais conhecidas são casamento de modelo, casamento sintático, classificação estatística e redes neurais. Tais modelos não são totalmente independentes e podem até ter interpretações diferentes ([FRIEDMAN; KANDEL, 1999](#)).

## 2.3 Aprendizado de Máquina

Aprendizado de máquina é uma das formas de realizar o reconhecimento de padrões, utilizando métodos estatísticos em um sistema a fim de prever os dados e/ou tomar decisões

(KOZA et al., 1996).

As principais formas de aprendizado são o supervisionado, não supervisionado, semi-supervisionado e o aprendizado por reforço.

- **Aprendizado Supervisionado:** Cada entrada de dado contém uma etiqueta associada - previamente classificada por um especialista -, dessa forma, o sistema, ao receber uma entrada, é capaz de definir qual etiqueta deve ser associada. Esta é a abordagem escolhida para este trabalho;
- **Aprendizado Não Supervisionado:** Ao contrário do anterior, os dados de entrada não possuem etiquetas associadas. Portanto, cabe ao sistema identificar as relações entre os dados. Geralmente, os dados são agrupados por características semelhantes;
- **Aprendizado Semi-Supervisionado:** Como o nome sugere, é uma abordagem que mistura os itens anteriores. Geralmente, apenas uma fração dos dados de entrada recebem algumas etiquetas, enquanto a maioria dos dados não receberá nenhuma etiqueta;
- **Aprendizado por Reforço:** Este método se diferencia dos anteriores devido à necessidade de interação com o usuário e/ou ambiente. Dessa forma, o sistema se ajusta automaticamente a fim de melhorar os próximos resultados.

## 2.4 Redes Neurais Artificiais

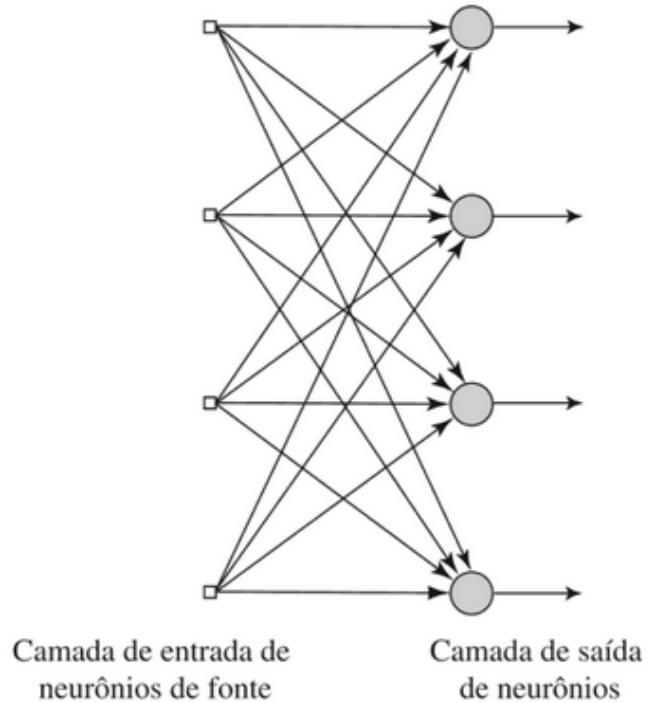
Pode-se ilustrar redes neurais como um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão para armazenar conhecimento e torná-lo disponível para uso. O conhecimento é adquirido pela rede através de um processo de aprendizagem e a conexão entre os neurônios para armazenar o conhecimento adquirido, assemelhando-se muito com o cérebro (HAYKIN, 2001).

Uma Rede Neural Artificial é definida por sua arquitetura e algoritmo de aprendizagem. A arquitetura é uma rede treinada através da generalização dos exemplos de treino por parte do algoritmo, armazenando o conhecimento nos parâmetros e os pesos das conexões na rede (RAUBER, 1997).

### 2.4.1 Redes Diretas com Camada Única

Em uma RNA Direta com Camada Única, os neurônios estão conectados em forma de camadas. Nesta abordagem mais simples, a camada de entrada é projetada sobre a camada de saída de maneira direta, ou seja, não cíclica. Uma rede com quatro nós tanto na camada de entrada quanto na de saída é mostrada na Figura 2 (HAYKIN, 2001).

Figura 2 – Rede direta com camada única não cíclica



#### 2.4.2 Redes Diretas com Múltiplas Camadas

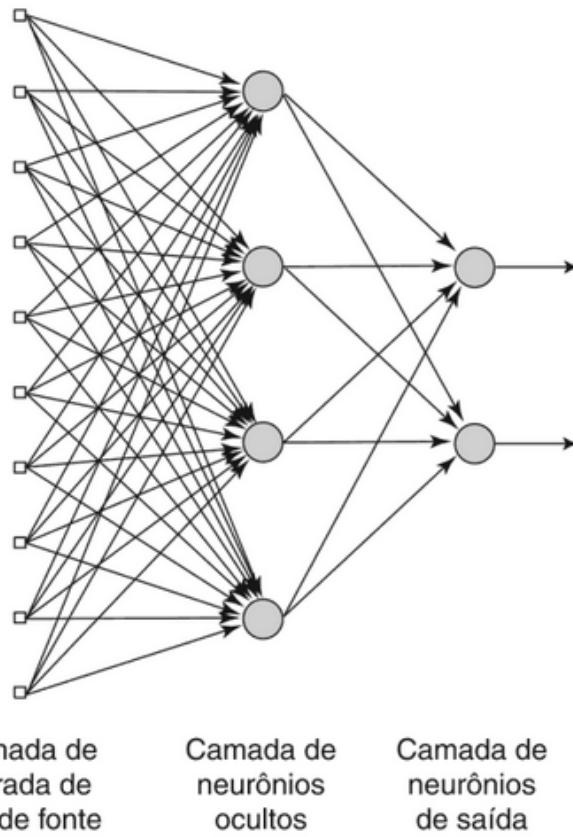
Em uma RNA Direta com Múltiplas Camadas, além das camadas de entrada e saída, existem uma ou mais camadas ocultas. Os neurônios presentes nas camadas ocultas têm a função de fazer um mapeamento entre a camada de entrada e a camada de saída. Esta abordagem é utilizada quando o tamanho da camada de entrada tem uma ordem elevada, assim como quando o problema a ser modelado é mais complexo. Os nós da camada de entrada são aplicados na segunda camada (primeira camada oculta). Os sinais da segunda camada são utilizados como entrada para a terceira camada (segunda camada oculta), e assim por diante, até chegar na camada de saída ([HAYKIN, 2001](#)). Esse processo está mostrado na [Figura 3](#).

### 2.5 Aprendizado Profundo

#### 2.5.1 Redes Convolucionais

Redes convolucionais são caracterizadas por suas camadas convolucionais, que processam as entradas. A principal aplicação desse tipo de rede é para o processamento de informações visuais, ou seja, imagens. A convolução permite processar as imagens considerando a sua estrutura espacial 2D ([PONTI; COSTA, 2018](#)).

Figura 3 – Rede direta com múltiplas camadas não cíclica



Fonte: [Haykin \(2001\)](#)

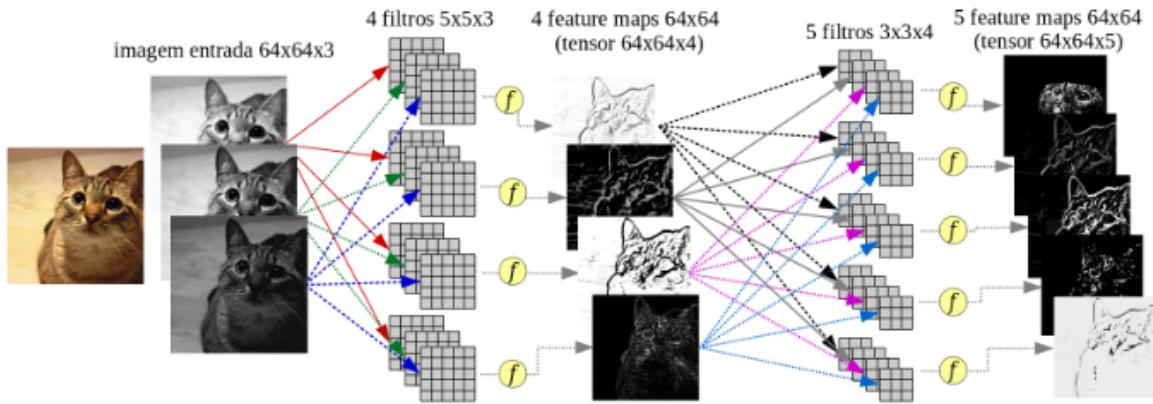
#### 2.5.1.1 Camada Convolucional

Nesta camada, cada neurônio é um filtro aplicado à imagem de entrada, resultando em uma matriz de peso. A [Figura 4](#) exemplifica duas camadas convolucionais de uma imagem de entrada com tamanho 64x64 com 3 canais de cores RGB. A primeira camada possui 4 filtros de tamanho 5, já a segunda camada possui 5 filtros de tamanho 3. Portanto, a saída da primeira camada terá uma dimensão de 64x64x4, pois possui 4 filtros, já a saída da segunda camada terá uma dimensão de 64x64x5. Uma função de ativação é aplicada sobre os filtros, essa função é chamada de função retificadora linear (do inglês, *rectified linear function*) que tem como objetivo padronizar o resultado da convolução para o intervalo de entrada.

#### 2.5.1.2 Pooling

A ação de reduzir a dimensão espacial dos mapas durante o processamento é chamada de *pooling*. Essa função aplica operações estatísticas em uma vizinhança a fim de encontrar, normalmente, um máximo ou a média. Como resultado, o *pooling* ajuda a reduzir o custo computacional ao reduzir a quantidade de dados gerados nas camadas convolucionais ([PONTI](#);

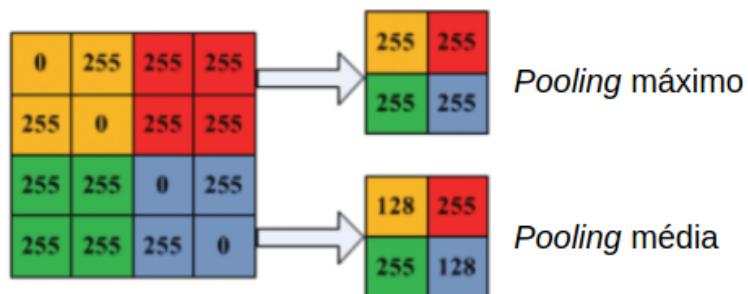
Figura 4 – Exemplificação de uma camada convolucional



Fonte: Ponti e Costa (2018)

COSTA, 2018). A Figura 5 exemplifica o funcionamento do processo de *pooling*.

Figura 5 – Processo de *pooling* máximo e média.



Fonte: Wanda e Jie (2020)

## 2.6 Processamento de Imagem

O processamento de imagens, derivada da área de processamento de sinais, tem como foco as imagens. É uma área que realiza diversas operações categorizadas por baixo, intermediário ou alto nível (JUNIOR, 2018).

- **Baixo nível:** Este nível compõe as operações mais básicas, como redução de ruídos e aumento de contraste. Este nível recebe uma imagem, como entrada, e retorna uma imagem;

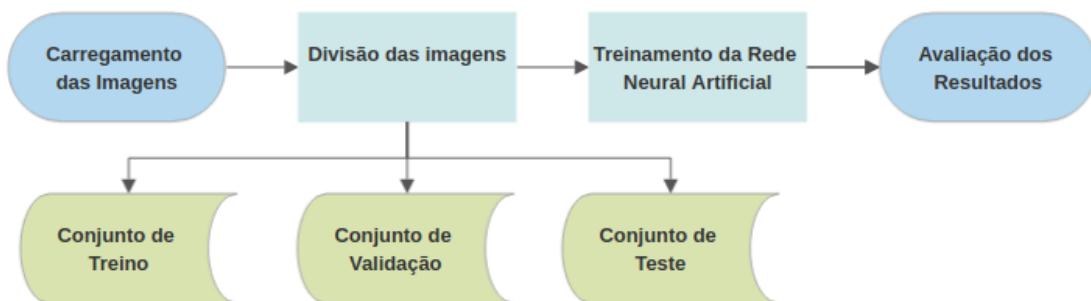
- **Nível intermediário:** Este nível compõe as operações de segmentação, análise e descrição de uma imagem. Por exemplo, detecção de borda e detecção de contorno. Este nível recebe, como entrada, uma imagem e tem, como saída, atributos da imagem;
- **Alto nível:** Por último, as operações de alto nível têm como objetivo extrair alguma informação da imagem. Por exemplo, através de operações de detecção e localização de objetos.

### 3 Desenvolvimento

Para classificar as doenças de plantas, foram utilizadas técnicas de processamento de imagens e aprendizado de máquina profundo. A linguagem de programação utilizada foi *Python*, que possui diversas bibliotecas já implementadas e prontas para serem usadas. Dentre essas, a *OpenCV*, para o tratamento de visão computacional e processamento de imagens; a *Keras*, para o modelo de redes neurais artificiais, a *Matplotlib* para manipulação dos gráficos gerados.

O desenvolvimento do classificador segue a sequência de passos ilustrada na [Figura 6](#), separando os passos em uma parte de pré-processamento e outra de aprendizado de máquina. Esta organização foi baseada no trabalho de [Sladojevic et al. \(2016\)](#), com algumas adaptações. Diferente do trabalho mencionado, utilizou-se o conjunto de dados disponível em [Mohanty, Hughes e Salathé \(2016\)](#), um conjunto de dados bem conhecido para este tipo de classificação e amplamente utilizado em diversos trabalhos, como no de [Toda e Okura \(2019\)](#).

Figura 6 – Sequência utilizada no desenvolvimento do classificador



Fonte: Elaborada pelo autor

#### 3.1 Conjunto de Dados

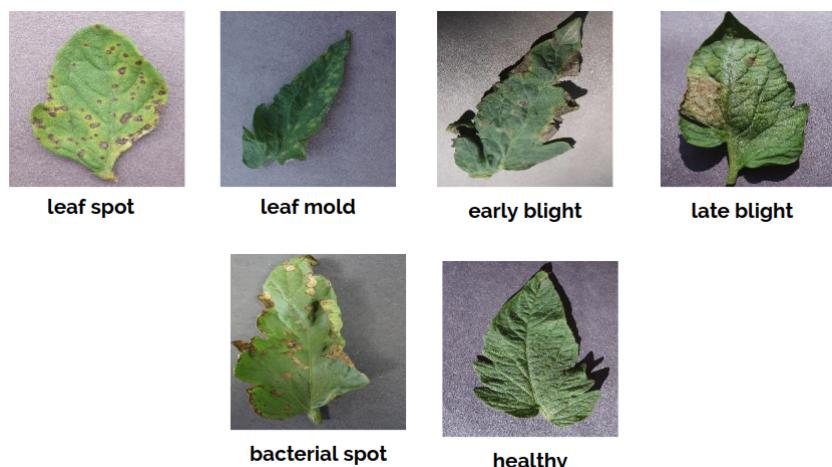
Para o conjunto de dados deste trabalho, escolheu-se o *PlantVillage*. Este conjunto de dados está disponível em repositório público no *GitHub*. Ele contém 54.306 imagens de 14 culturas diferentes, identificadas em 38 classes ([MOHANTY; HUGHES; SALATHÉ, 2016](#)).

Por ser um conjunto de dados muito grande e o objetivo deste trabalho ser uma prova de conceito, realizou-se uma seleção de um subconjunto desse conjunto de dados. O novo conjunto de dados contém, aproximadamente, 9 mil imagens.

Neste novo subconjunto, escolheu-se trabalhar com imagens de tomate e, a partir desta cultura, imagens da planta saudável e de 5 doenças diferentes. Ao analisar as imagens das doenças de tomate, foi possível notar semelhanças entre algumas doenças, entre elas a *Early Blight* e *Late Blight*, assim como *Leaf Mold* e *Leaf Spot*.

A [Figura 7](#) mostra um exemplo de cada classe do subconjunto criado para este trabalho. Nesta figura, a amostra da doença *Leaf Spot* apresenta pontos escuros na folha, enquanto a *Leaf Mold* apresenta pontos claros em toda folha. Já a *Early Blight* apresenta manchas escuras nas extremidades, enquanto a *Late Blight* apresenta uma mancha escura na extremidade. A *Bacterial Spot*, por sua vez, apresenta manchas claras nas extremidades e no interior da folha. Por fim, a amostra da classe *Healthy* não apresenta mancha alguma.

[Figura 7 – Amostras das classes do conjunto de dados](#)



Fonte: Elaborada pelo autor

## 3.2 Pré-processamento

Inicialmente foi separado o conjunto de dados disponível em [Mohanty, Hughes e Salathé \(2016\)](#) nos conjuntos de treino, validação e teste usando a proporção de 70% para o conjunto de treino, 15% para o conjunto de validação e 15% para o conjunto de teste.

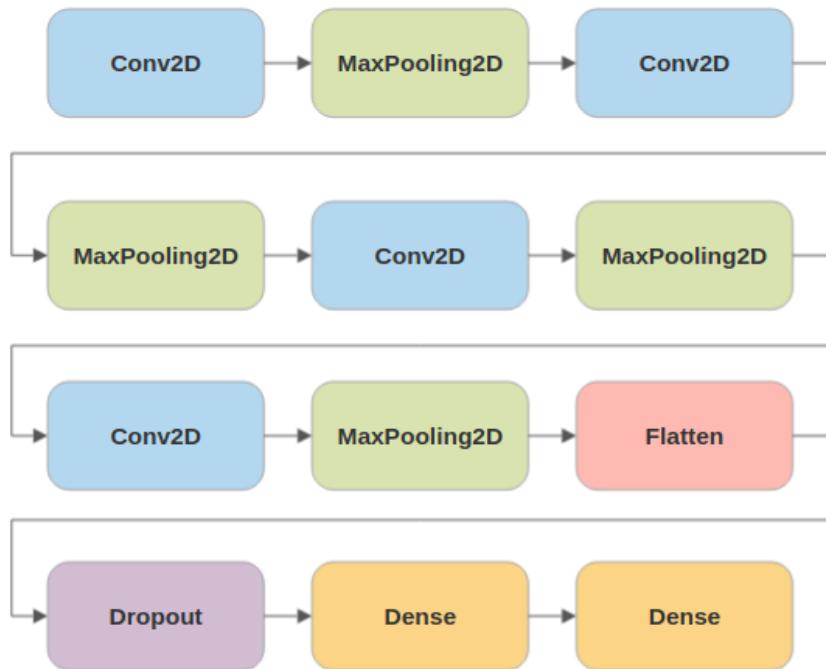
Para carregamento das imagens, foi utilizada a classe *ImageDataGenerator*, da biblioteca *Keras*, que é capaz de carregar as imagens em lotes otimizando, assim, o uso de memória durante o processo de treinamento da rede neural. Além disso, é realizado um redimensionamento das imagens para o tamanho 150 x 150, a fim de agilizar o processamento das imagens.

Por fim, é feita uma normalização para que as entradas da imagem fiquem no intervalo de (0, 1).

### 3.3 Aprendizado de Máquina

Após o pré-processamento, as imagens estão prontas para darem início à etapa de aprendizado de máquina. A arquitetura profunda adotada neste trabalho utiliza as ferramentas da biblioteca *Keras*. As camadas utilizadas foram *Conv2D*, *MaxPooling2D*, *Dropout*, *Flatten* e *Dense*. Uma representação do modelo final pode ser vista na [Figura 8](#).

Figura 8 – Representação do modelo construído



Fonte: Elaborada pelo autor

#### 3.3.1 Conv2D

A primeira camada deste modelo, *Conv2D*, é uma camada Convolucional que trabalha sobre dados 2D, neste caso, com as imagens. O funcionamento de redes convolucionais foi descrito na [subseção 2.5.1](#).

#### 3.3.2 MaxPooling2D

A segunda camada, *MaxPooling2D* realiza um *pooling* máximo nas imagens. O conceito de *pooling* foi definido na [subseção 2.5.1.2](#).

### 3.3.3 *Flatten*

A camada de *Flatten* não possui parâmetros a serem treinados. Sendo assim, sua função é acharar os dados, ou seja, transformar os dados multidimensionais em unidimensionais.

### 3.3.4 *Dropout*

A camada *Dropout* é responsável por diminuir o tamanho da rede neural artificial, eliminando aleatoriamente algumas conexões entre os neurônios. Isso serve como uma regularização e também ajuda a reduzir o sobreajuste. Esta camada, como a anterior, não possui parâmetros a serem treinados, auxiliando apenas no desenvolvimento da rede neural artificial.

### 3.3.5 *Dense*

Por fim, a camada *Dense* representa uma camada padrão de uma rede neural direta simples completamente conectada. Essa estrutura é utilizada em redes neurais artificiais mais simples, como mencionado na [subseção 2.4.1](#).

Essa camada, por sua vez, é responsável por pegar os dados obtidos das camadas anteriores e realizar a predição final da classe correspondente à imagem de entrada.

## 3.4 Avaliação dos Resultados do Treinamento

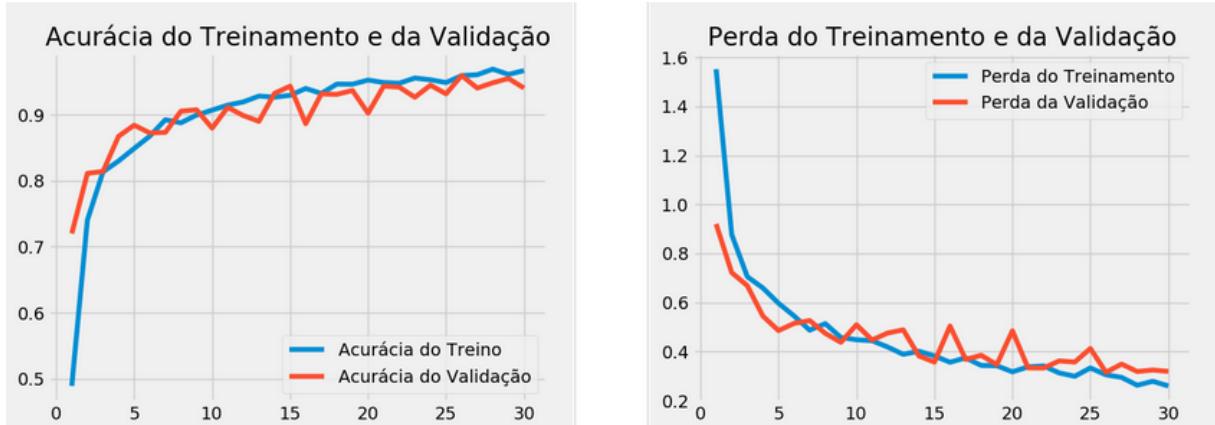
O modelo desenvolvido foi treinado usando duas abordagens diferentes. A primeira usou imagens no espaço de cor RGB, já a segunda utilizou imagens em escala de cinza. O treinamento dos modelos foi realizado utilizando um computador com um processador Intel Core i3-7100 operando a 3.90GHz, uma placa de vídeo GeForce GTX 1050 de 2GB e 8GB de memória RAM, no sistema operacional *Linux*.

A versão da linguagem *Python* utilizada foi a 3.6.7, a versão da biblioteca *Keras* foi a 2.2.4, com o *Tensorflow* 1.11.0 como *backend*.

### 3.4.1 Abordagem RGB

Ao fim do treinamento, na abordagem com imagens RGB, o classificador obteve acurácia de aproximadamente 96,4% e 0,29 de *loss*. A evolução dos valores durante o treinamento do modelo pode ser vista na [Figura 9](#). O treinamento foi realizado com 30 épocas, isto é, passando 30 vezes por cada uma das imagens dos conjuntos de treinamento e validação. Foi possível observar que, em apenas 9 épocas, o modelo já atingiu 92% para acurácia. Analisando os gráficos da evolução da acurácia e *loss*, entende-se que o classificador não sofreu sobreajuste, dado que os valores para o conjunto de validação são compatíveis com os obtidos no conjunto de testes.

Figura 9 – Evolução da acurácia e *loss* durante o treinamento usando imagens coloridas



Fonte: Elaborada pelo autor

Ao testar o modelo treinado, obteve-se aproximadamente 95,6% de acurácia. A frequência de classificação para cada classe é chamada de matriz de confusão, conforme Souza (2019). A Figura 10 mostra quais classes estão se confundindo neste modelo. Foram utilizados os nomes das doenças em inglês para fins de consistência com o conjunto de dados utilizado. Nota-se que, as classes não apresentaram sobreposição, isto é, muitas imagens sendo classificadas incorretamente como sendo de outras classes.

Desse modo, pode-se concluir que o modelo consegue definir bem as classes propostas neste trabalho. Analisando a matriz, é possível identificar que a maior confusão ocorre entre as classes *Leaf Mold* e *Leaf Spot*. Mesmo assim, a proporção de imagens confundidas entre essas classes não é tão alto, sendo de apenas 8%.

### 3.4.2 Abordagem em Escalas de Cinza

Nesta abordagem, o classificador obteve aproximadamente 86,9% de acurácia e 0,54 de *loss*. A evolução dos valores durante o treinamento do modelo pode ser vista na Figura 11. O treinamento, assim como na abordagem anterior, foi realizado com 30 épocas. Diferentemente do treinamento anterior que, em 9 épocas, já tinha atingido 92% de acurácia, com o mesmo número de épocas, este ainda atingia 80% para acurácia. Também entende-se que este classificador não sofreu de sobreajuste, pelos mesmos motivos expostos anteriormente.

Ao testar o modelo após este novo treinamento, obteve-se aproximadamente 83,2% de acurácia, uma redução de 12,4% em comparação com o anterior. A matriz de confusão mostrada na Figura 12 exibe quais classes estão se confundindo neste treinamento.

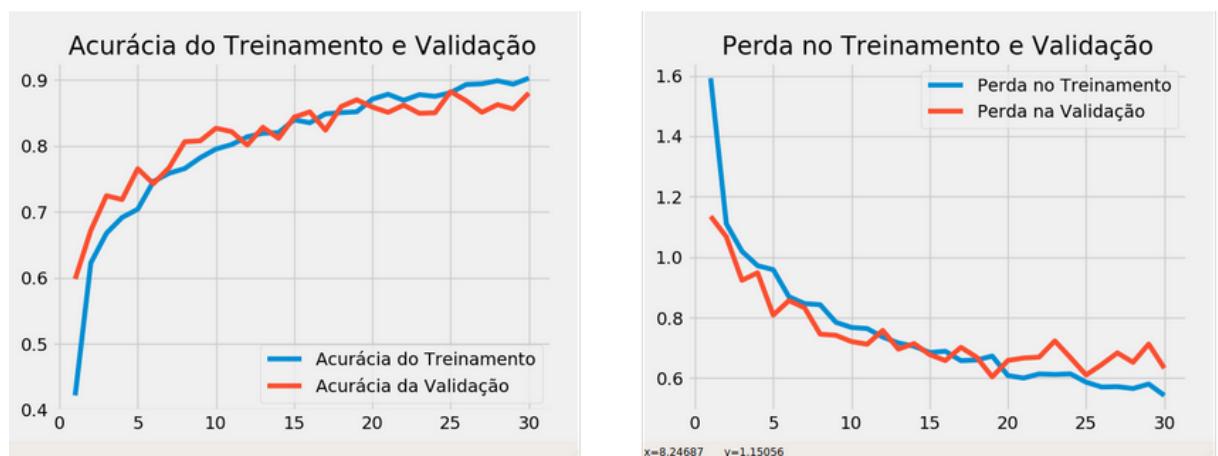
Diferentemente da anterior, esta abordagem apresenta como possuindo maior confusão, as classes *Early Blight* e *Late Blight*, sendo 22% das imagens desta última classe classificadas incorretamente como *Early Blight*. Apesar disso, os altos valores presentes na diagonal principal

Figura 10 – Matriz de confusão do treinamento com imagens coloridas

	Bacterial Spot	Early Blight	Late Blight	Leaf Mold	Leaf Spot	Healthy
Bacterial Spot	0.99	0.01	0	0	0	0
Early Blight	0.02	0.87	0.02	0.01	0.03	0
Late Blight	0	0.07	0.95	0.01	0	0
Leaf Mold	0	0.01	0.01	0.94	0.01	0.01
Leaf Spot	0.01	0.02	0.03	0.08	0.89	0.01
Healthy	0	0	0	0	0	1

Fonte: Elaborada pelo autor

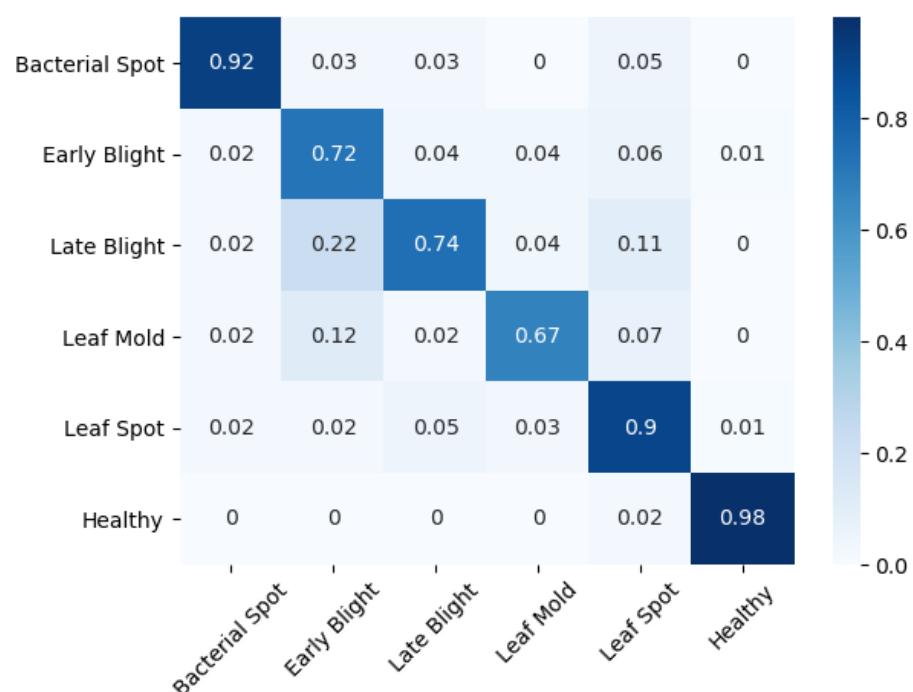
Figura 11 – Evolução da acurácia e *loss* durante o treinamento usando imagens monocromáticas



Fonte: Elaborada pelo autor

da matriz de confusão, demonstram que, embora tenha uma acurácia menor, este modelo também apresenta resultados satisfatórios para a classificação automática das doenças.

Figura 12 – Matriz de confusão do treinamento com imagens monocromáticas



Fonte: Elaborada pelo autor

## 4 Conclusão

Em [Sharma, Hans e Gupta \(2020\)](#), os autores mostraram que redes neurais artificiais convolucionais eram a melhor abordagem para a classificação de doenças em plantas, então, por este motivo, estas redes foram utilizadas neste trabalho. [Sharma, Hans e Gupta \(2020\)](#) utilizaram apenas imagens HSV, alegando que poderiam ser mais apropriadas para a identificação das doenças. Portanto, esse trabalho preocupou-se em expandir essa análise fazendo um estudo usando os outros espaços de cor mais comuns, o RGB e o de tons de cinza, para avaliar os resultados obtidos através de seu uso.

Assim como no trabalho de [Sardogan, Tuncer e Ozen \(2018\)](#), foram analisadas as doenças em folhas de tomates, porém, a análise foi expandida. Em [Sardogan, Tuncer e Ozen \(2018\)](#) foi utilizado um conjunto de dados relativamente pequeno, de apenas 500 imagens e exclusivamente doenças bastante diferentes entre si. Neste trabalho, entretanto, foram utilizadas mais imagens e selecionadas classes que apresentam padrões mais parecidos, como a *Early Blight* e *Late Blight*, que são mais suscetíveis a confusão, como foi mostrado na [Figura 12](#).

Com base nos resultados obtidos, conclui-se que as duas abordagens empregadas, a saber, o uso de imagens monocromáticas e coloridas (RGB), atendem de maneira satisfatória o objetivo inicial de reconhecer doenças em plantas. Cabe notar que, de acordo com os dados, a abordagem RGB apresentou melhores resultados, dado que sua acurácia foi de 95,6%, enquanto a abordagem em tons de cinza apresentou uma acurácia de 83,2%, ou seja, uma diferença de 12,4% nos testes.

Apesar de apresentar um avanço em relação aos trabalhos da literatura, diversos pontos de melhora nesse trabalho podem ser observados. A adição de outras doenças, ou mesmo de outras plantas enriqueceria a análise aumentando a generalização do sistema, de modo a tornar-se útil para ainda mais pessoas.

Ainda visando melhorar a utilidade e usabilidade do sistema, um caminho natural seria o desenvolvimento de um aplicativo móvel para facilitar o uso do sistema em situações reais. Isso contribuiria, como mencionado na [Capítulo 1](#), pois, dessa maneira, não será necessária a análise de um especialista para realizar a classificação das doenças, que é um processo difícil, caro e suscetível a erros.

Observa-se, então, que o uso de sistemas computacionais, mais especificamente os de reconhecimento de padrões através de visão computacional, agregam muito à agricultura de precisão, fornecendo resultados satisfatórios em relação aos obtidos por humanos (ou melhores, em muitos casos) com redução de gastos e tempo.

# Referências

- AGRIOS, G. N. *Plant Pathology*. Oxford, Inglaterra: Elsevier Science, 2005. ISBN 9780080473789.
- ANGHINONI, I.; FERREIRA, T.; DENARDIN, L. G.; MARTINS, A.; CARVALHO, P. D. F.; MORAES, A. de. Agricultura brasileira: dos primórdios aos sistemas integrados de produção agropecuária. In: *Sistemas Integrados de Produção Agropecuária no Brasil*. [S.I.: s.n.], 2018. p. 29–38. ISBN 9878583881117.
- BALASTREIRE, L. A. *O estado da arte da agricultura de precisão no Brasil*. Piracicaba: O autor, 2000.
- BERNARDI, A. d. C.; NAIME, J. D. M.; RESENDE, A. D.; BASSOI, L.; INAMASU, R. *Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa, 2014. ISBN 978-85-7035-352-8.
- BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Nova Iorque: Springer-Verlag, 2006. ISBN 978-0-387-31073-2.
- BOCK, C. H.; POOLE, G. H.; PARKER, P. E.; GOTTWALD, T. R. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, Taylor & Francis, v. 29, n. 2, p. 59–107, 2010.
- CAROLLO, E. M.; FILHO, H. P. S. *Manual básico de técnicas fitopatológicas: laboratório de fitopatologia Embrapa Mandioca e Fruticultura*. Cruz das Almas, BA: Embrapa Mandioca e Fruticultura, 2016.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2nd edition. ed. Estados Unidos: John Wiley & Sons, Inc., 2000. ISBN 978-0-471-05669-0.
- FRIEDMAN, M.; KANDEL, A. Introduction to pattern recognition - statistical, structural, neural and fuzzy logic approaches. In: *Series in Machine Perception and Artificial Intelligence*. [S.I.]: Imperial College Press, 1999. ISBN 9810233124.
- HAYKIN, S. *Redes Neurais: Princípios e práticas*. [S.I.]: Prentice Hall, Inc., 2001.
- HUANG, T. S. Computer vision: Evolution and promise. *19th CERN School of Computing*, p. 21–25, 1996.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, p. 4–37, 2000.
- JUNIOR, J. C. S. J. *Processamento de Imagens: fundamentos*. Pontifícia Universidade Católica do Rio Grande do Sul, 2018. Disponível em: <[https://www.inf.pucrs.br/~smusse/Simulacao/PDFs/aula\\_02\\_Fundamentos\\_PI.pdf](https://www.inf.pucrs.br/~smusse/Simulacao/PDFs/aula_02_Fundamentos_PI.pdf)>. Acesso em: 23 nov. 2019.
- KOZA, J. R.; BENNETT, F. H.; ANDRE, D.; KEANE, M. A. Automated design of both the topology and sizing of analog electrical circuits using genetic programming. In: GERO, J. S.; SUDWEEKS, F. (Ed.). *Artificial Intelligence in Design '96*. Dordrecht: Springer Netherlands, 1996. p. 151–170. ISBN 978-94-009-0279-4.

- MICHAELIS. *Image Convolution*. Editora Melhoramentos Ltda, 2015. Disponível em: <<https://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/agricultura>>. Acesso em: 10 mar. 2020.
- MOHANTY, S. P.; HUGHES, D. P.; SALATHé, M. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, v. 7, p. 1419, 2016. Disponível em: <<https://www.frontiersin.org/article/10.3389/fpls.2016.01419>>.
- PENG, Y.; REGGIA, J. A. *Abductive Inference Models for Diagnostic Problem-Solving*. Berlin, Heidelberg: Springer-Verlag, 1990. ISBN 978-1-4419-8682-5.
- PONTI, M. A.; COSTA, G. B. P. da. Como funciona o deep learning. *CoRR*, abs/1806.07908, 2018. Disponível em: <<http://arxiv.org/abs/1806.07908>>.
- RAUBER, T. W. Redes neurais artificiais. *Universidade Federal do Espírito Santo*, p. 29, 1997.
- SANNAKKI, S. S.; RAJPUROHIT, V. S.; NARGUND, V. B.; R, A. K.; YALLUR5, P. S. Vleaf disease grading by machine vision and fuzzy logic. *Int. J. Comp. Tech. Appl.*, p. 1709–1716, 2011.
- SANTOS, T. T.; YASSITEPE, J. E. D. C. T. Fenotipagem de plantas em larga escala: um novo campo de aplicação para a visão computacional na agricultura. *Embrapa Informática Agropecuária*, p. 85–100, 2014.
- SARDOGAN, M.; TUNCER, A.; OZEN, Y. Plant leaf disease detection and classification based on cnn with lvq algorithm. In: *2018 3rd International Conference on Computer Science and Engineering (UBMK)*. [S.I.: s.n.], 2018. p. 382–385.
- SHARMA, P.; HANS, P.; GUPTA, S. C. Classification of plant leaf diseases using machine learning and image preprocessing techniques. In: *2020 10th International Conference on Cloud Computing, Data Science Engineering (Confluence)*. [S.I.: s.n.], 2020. p. 480–484.
- SLADOJEVIC, S.; ARSENOVIC, M.; ANDERLA, A.; CULIBRK, D.; STEFANOVIĆ, D. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, vol. 2016, p. 11, 2016. Disponível em: <<https://www.hindawi.com/journals/cin/2016/3289801/>>.
- SOUZA, E. G. de. *Entendendo o que é Matriz de Confusão com Python*. Data Hackers, 2019. Disponível em: <<https://medium.com/data-hackers/entendendo-o-que-%C3%A9-matriz-de-confus%C3%A3o-ao-com-python-114e683ec509>>. Acesso em: 21 out. 2019.
- TODA, Y.; OKURA, F. How convolutional neural networks diagnose plant disease. *Plant Phenomics*, vol. 2019, p. 14, 2019. Disponível em: <<https://doi.org/10.34133/2019/9237136>>.
- WANDA, P.; JIE, H. Runpool: A dynamic pooling layer for convolution neural network. *International Journal of Computational Intelligence Systems*, v. 13, 01 2020.