



**VISÃO COMPUTACIONAL E APRENDIZAGEM
PROFUNDA NO RECONHECIMENTO DE PRAGAS DE
PLANTACÕES DE ALGODÃO**

Adão Nunes Alves

**Dissertação de Mestrado
Sistemas Mecatrônicos**

UNIVERSIDADE DE BRASÍLIA

**Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

**VISÃO COMPUTACIONAL E APRENDIZAGEM
PROFUNDA NO RECONHECIMENTO DE PRAGAS DE
PLANTAÇÕES DE ALGODÃO**

Adão Nunes Alves

Orientador: Díbio Leandro Borges, Ph.D. (CiC/UnB)

DISSERTAÇÃO DE MESTRADO

PUBLICAÇÃO: ENM.DM - XXX.XXX

BRASÍLIA/DF: 16 de agosto de 2019

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

**Visão Computacional e Aprendizagem Profunda no
Reconhecimento de Pragas de Plantações de Algodão**

Adão Nunes Alves

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA MECÂNICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS PARCIAIS PARA A OBTENÇÃO DO GRAU DE MESTRE EM SISTEMAS MECATRÔNICOS.

APROVADA POR:

Díbio Leandro Borges, Ph.D. (CiC/UnB)
(Orientador)

Flávio de Barros Vidal, Dr. (CiC/UnB)
(Examinador Interno)

Marcelo Ladeira, Dr. (CiC/ UnB)
(Examinador Externo)

BRASÍLIA/DF, 16 DE AGOSTO DE 2019.

FICHA CATALOGRÁFICA

Alves, Adão. Nunes.

Visão Computacional e Aprendizagem Profunda no Reconhecimento de Pragas de Plantações de Algodão

[Distrito Federal] 2019.

xvii, 84p. (ENM/FT/UnB, Mestre, Sistemas Mecatrônicos, 2019.

Dissertação de Mestrado - Universidade de Brasília.

Faculdade de Tecnologia.

Departamento de Engenharia Mecânica.

Palavras-chave:

1. Classificação por imagens de pragas do algodoeiro

2. Aprendizagem residual profunda

3. Banco de imagens de campo

I. ENM/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

Alves, Adão. Nunes. (2019). Visão Computacional e Aprendizagem Profunda no Reconhecimento de Pragas de Plantações de Algodão. Dissertação de Mestrado, Publicação ENM.DM - XXX.XXX, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, Distrito Federal, xvii, 84p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Adão Nunes Alves.

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Visão Computacional e Aprendizagem Profunda no Reconhecimento de Pragas de Plantações de Algodão.

GRAU / ANO: MESTRE / 2019

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

Adão Nunes Alves

Dedico este trabalho aos meus pais, Debas e Aparecida, com todo meu amor e gratidão, por tudo o que fizeram por mim ao longo de minha vida. Quero dizer que esta conquista não é só minha, mas nossa. Tudo o que consegui só foi possível graças ao amor, ao apoio e à dedicação que vocês sempre tiveram por mim. Sempre me ensinaram agir com respeito, simplicidade, dignidade, honestidade e amor ao próximo. E, graças à união de todos, os obstáculos foram ultrapassados, vitórias foram conquistadas e agora posso compartilhar esta alegria com vocês.

Agradecimentos

Ao longo de todo o processo que levou à realização deste trabalho, tive a sorte e o privilégio de ter conhecido pessoas realmente fantásticas, sem as quais não teria sido possível chegar até aqui e das quais nunca me vou esquecer. Tive também a sorte de contar com o apoio daqueles que, mais uma vez e em mais uma importante etapa da minha vida, estiveram realmente presentes. Assim, com todas as palavras que aqui dedico, sei que não conseguirei de todo modo descrever o quão privilegiado me sinto. Início agradecendo a Deus, por ter abençoado todos os dias da minha vida, por iluminar meu caminho, dar-me forças para seguir sempre em frente e permitir alcançar essa maravilhosa conquista. Aos meus pais, Debas e Aparecida, meu infinito agradecimento. À minha irmã, Eva, o meu muito obrigado, sem você nada seria igual nem tão perfeito. À minha namorada, Erika, que sempre esteve presente e me apoiou quando mais precisava e, por isso, agradeço-lhe por toda a companhia e apoio que me tem dado e toda a sua paciência comigo.

*Ao meu orientador, **Professor Díbio Leandro Borges**, gostaria de deixar um agradecimento muito especial. Por todo o conhecimento compartilhado, pelo apoio e confiança, por estar sempre pronto para ajudar e por ter acreditado na minha capacidade. Vai sempre ser uma referência na minha vida profissional.*

A todos os amigos e colegas que, de forma direta ou indireta, contribuíram, ou auxiliaram na elaboração do presente estudo, pela paciência, atenção e força que prestaram em momentos menos fáceis. Para não correr o risco de não enumerar algum, não irei identificar ninguém, àqueles a quem este agradecimento se dirige, sabê-lo-ão: desde já, deixo os meus agradecimentos.

Resumo

Visão Computacional e Aprendizagem Profunda no Reconhecimento de Pragas de Plantações de Algodão

Autor: Adão Nunes Alves

Orientador: Díbio Leandro Borges, Ph.D. (CiC/UnB)

Programa de Pós Graduação em Sistemas Mecatrônicos

Brasília, 16 de agosto de 2019

As pragas na agricultura são consideradas causas importantes de perdas nas lavouras em todo o mundo. O algodão é uma fonte importante de fibras têxteis, e as pragas e seu manejo são os maiores custos variáveis na produção de algodão. Identificar as pragas de algodão mais prejudiciais em condições de campo contribui para ações ainda mais eficientes com estratégias ambientalmente aceitáveis e, ainda, economicamente eficazes. Nesta dissertação, propõe-se desenvolver um sistema de classificação para quinze categorias de pragas de algodão (primárias e secundárias) e mensurar o seu desempenho considerando imagens de campo, organizados em um novo conjunto de dados de imagens RGB de campos de algodão. Os testes são realizados com diferentes classificadores, e uma rede residual profunda modificada (ResNet34*) é proposta para tarefa, a qual obteve em média a melhor taxa de acerto na validação cruzada com a precisão de 98,1%.

Palavras-chaves: Classificação por imagens de pragas do algodoeiro; Aprendizagem residual profunda; Banco de imagens de campo.

Abstract

COMPUTER VISION AND DEEP LEARNING IN PESTS RECOGNITION OF COTTON PLANTATIONS

Author: Adão Nunes Alves

Supervisor: Díbio Leandro Borges, Ph.D. (CiC/UnB)

Master in Mechatronic Systems

Brasília, 2019

Pests in agriculture are deemed to be important cause of losses in crops worldwide. Cotton is an important source of textile fiber, and insect pests and their management are the highest variable cost in cotton production. Identifying the most harmful cotton pests in field conditions helps further efficient actions for environmentally acceptable and yet economically effective strategies. In this research, a classification system for fifteen major cotton pests (primary and secondary) is proposed and its performance considered upon field-image data, organized in a new ground-truth dataset of cotton fields RGB images. Tests are performed with different classifiers and a modified deep residual network (ResNet34*) is proposed for the task achieving the highest mean accuracy of 98.1% in the cross validation test.

Key-words: Cotton pests image classification; Residual deep learning; Field-images dataset.

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	6
1.2	Metodologia de pesquisa	7
1.3	Organização do trabalho	7
2	REVISÃO BIBLIOGRÁFICA	8
2.1	Pragas em Lavouras	8
2.2	Pragas do Algodoeiro	8
2.2.1	<i>Anthonomus grandis</i>	10
2.2.2	<i>Aphis gossypii</i>	10
2.2.3	<i>Helicoverpa armigera</i>	11
2.2.4	<i>Heliothis virescens</i>	11
2.2.5	<i>Pseudoplusia includens</i>	12
2.2.6	<i>Spodoptera frugiperda</i>	12
2.2.7	<i>Alabama argillacea</i>	13
2.2.8	<i>Bemisia tabaci</i>	13
2.2.9	<i>Horcias nobilellus</i>	14
2.2.10	<i>Pectinophora gossypiella</i>	14
2.2.11	<i>Spodoptera eridania</i>	15
2.2.12	<i>Tetranychus urticae</i>	16
2.3	Reconhecimento Visual de Pragas	16
3	MATERIAL E MÉTODOS	20
3.1	Conjunto de Dados	21
3.2	Técnicas de Reconhecimento	24
3.2.1	Redes Neurais Convolucionais (RNCs)	26
3.2.1.1	Camada Convolucional	28
3.2.1.2	Camadas de seleção e agrupamento (<i>pooling</i>)	29
3.2.1.3	Camada Totalmente Conectada	30
3.2.2	ALexNet	31

3.2.3	ResNet-34	31
3.2.4	Resnet-34*	33
3.2.5	ResNet-50	34
3.3	Processo de Treinamento	36
3.3.1	Processo de treinamento para pragas primárias	39
3.3.2	Processo de treinamento para todas as pragas	41
4	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	44
4.1	Experimentos	44
4.2	Análise de Resultados	59
5	CONCLUSÕES	62
	REFERÊNCIAS BIBLIOGRÁFICAS	64
	APÊNDICES	67
	APÊNDICE A – EXEMPLOS DE IMAGENS DO BANCO CONSTRUÍDO	68

Lista de Figuras

Figura 2.1 – Pragas primárias do algodão em seus diferentes estádios. Adaptado de (MONSANTO, 2015)	9
Figura 2.2 – Imagens de <i>Anthonomus grandis</i>	10
Figura 2.3 – Imagens de <i>Aphis gossypii</i>	11
Figura 2.4 – Imagens de <i>Helicoverpa armigera</i>	11
Figura 2.5 – Imagens de <i>Heliothis virescens</i>	12
Figura 2.6 – Imagens de <i>Pseudoplusia includens</i>	12
Figura 2.7 – Imagens de <i>Spodoptera frugiperda</i>	13
Figura 2.8 – Imagens de <i>Alabama argillacea</i>	13
Figura 2.9 – Imagens de <i>Bemisia tabaci</i>	14
Figura 2.10 – Imagens de <i>Horcias nobilellus</i>	14
Figura 2.11 – Imagens de <i>Pectinophora gossypiella</i>	15
Figura 2.12 – Imagens de <i>Spodoptera eridania</i>	16
Figura 2.13 – Imagens <i>Tetranychus urticae</i>	16
Figura 3.1 – Imagens ilustrativas das quatro fases utilizadas no processo de reconhecimento das principais pragas da cultura algodoeira por imagens de campo.	20
Figura 3.2 – Ilustração de transformações realizadas em imagens do conjunto de dados de pragas primárias. (a) Imagem original; (b) Rotação de 90°; (c) Rotação de -90°; (d) Rotação de 180°; (e) Zoom aleatório de até 1,5x; (f) Alongamento aleatório; (g) Rotação aleatória máxima dentro de um intervalo de 10° graus; (h) Variação de intensidade de pixel para simular diferentes condições de iluminação.	21
Figura 3.3 – Ilustração de transformações realizadas em imagens do conjunto de dados de pragas secundárias. (a) Imagem original; (b) Rotação de 90°; (c) Rotação de -90°; (d) Rotação de 180°; (e) Zoom aleatório de até 1,5x; (f) Alongamento aleatório; (g) Rotação aleatória máxima dentro de um intervalo de 10° graus; (h) Variação de intensidade de pixel para simular diferentes condições de iluminação.	22

Figura 3.4 – Imagens de pragas de campo para classe primárias: a, b) <i>Anthonomus grandis</i> , c, d) <i>Aphis gossypii</i> , e) <i>Helicoverpa armigera</i> (larva), f) <i>Helicoverpa armigera</i> (adulta), g) <i>Heliothis virescens</i> (larva), h) <i>Heliothis virescens</i> (adulta), i, j) <i>Pseudoplusia includens</i> , k) <i>Spodoptera frugiperda</i> (larva), l) <i>Spodoptera frugiperda</i> (adulta).	23
Figura 3.5 – Imagens de pragas de campo para classe secundárias: a, b) <i>Alabama argillacea</i> , c, d) <i>Bemisia tabaci</i> , e, f) <i>Horcias nobilellus</i> , g, h) <i>Pectinophora gossypiella</i> , i, j) <i>Spodoptera eridania</i> , k, l) <i>Tetranychus urticae</i>	23
Figura 3.6 – Exemplo de extração de LBP. A matriz em escala de cinza representa a amostra de uma imagem, em seguida a matriz central da figura descreve os valores números para escala de cinza (0 até 255). Por fim a matriz binarizada à direita da matriz numérica apresenta a transformação aplicada, em que os valores acima de 127 equivale a 1 e os abaixo são equivalentes a 0.	25
Figura 3.7 – Ilustração de um modelo de aplicação da convolução na imagem. À esquerda, uma imagem hipoteticamente representada por um único canal com dimensões 5x5 que recebe a aplicação de um filtro 3x3. À direita, uma matriz ilustrando o somatório que fornece o resultado da convolução.	27
Figura 3.8 – Ilustração da arquitetura de uma rede neuronal convolucional padrão que classifica imagens de entradas com imagens de pragas do algodão ou não pragas e suas três principais camadas: convolucionais, de <i>pooling</i> e totalmente conectadas.	28
Figura 3.9 – Ilustração da convolução de uma imagem colorida(RGB) entre um filtro 3x3.	29
Figura 3.10–Aplicação de <i>max pooling</i> em uma imagem 4x4, utilizando um filtro 2x2. Além de reduzir o tamanho da imagem, consequentemente reduzindo o processamento para as próximas camadas, essa técnica também auxilia no tratamento de invariâncias locais.	30
Figura 3.11–Modelo de arquitetura da AlexNet padrão.	31
Figura 3.12–Arquitetura de um bloco residual.	32
Figura 3.13–Redes regulares (a) e residuais (b) profundas típicas mostrando o fluxo de informação entre as camadas.	33
Figura 3.14–ResNet-34* modificada: a última camada linear do modelo original é substituída por 7 camadas adicionais lineares originais.	34
Figura 3.15–Arquitetura de uma rede residual (ResNet-50)	35
Figura 3.16–Etapas de Treinamento (a), Validação (b) e Precisão (c) da abordagem de varredura para taxa de aprendizagem inicial dentro do intervalo testado de 10^{-22} a 10^1	38
Figura 3.17–Gráfico de erro de validação e treinamento com a precisão de validação da AlexNet (pragas primárias).	39

Figura 3.18–Gráfico erro de validação e treinamento com a precisão de validação da ResNet-34 (pragas primárias).	40
Figura 3.19–Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-34* (pragas primárias).	40
Figura 3.20–Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-50 (pragas primárias).	41
Figura 3.21–Gráfico de erro de validação e treinamento com a precisão de validação da AlexNet (todas as pragas).	41
Figura 3.22–Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-34 (todas as pragas)	42
Figura 3.23–Gráfico de erro de validação e treinamento com a precisão de validação da Resnet-34* (todas as pragas).	42
Figura 3.24–Gráfico de erro de validação e treinamento com a precisão de validação da Resnet-50 (todas as pragas).	43
Figura 4.1 – Matriz de confusão gerada pelo classificador LBP-SVM, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) <i>Anthonomus grandis</i> , 2) <i>Aphis gossype</i> , 3) <i>Helicoverpa amigera</i> , 4) <i>Helicoverpa amigera adulta</i> , 5) <i>Heliothis virescens</i> , 6) <i>Heliothis virescens adulta</i> , 7) <i>Spodoptera frugiperda</i> , 8) <i>spodoptera frugiperda adulta</i> , 9) Não Praga, 10) <i>Pseudoplusia includens</i>	45
Figura 4.2 – Matriz de confusão gerada pelo classificador AlexNet, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) <i>Anthonomus grandis</i> , 2) <i>Aphis gossype</i> , 3) <i>Helicoverpa amigera</i> , 4) <i>Helicoverpa amigera adulta</i> , 5) <i>Heliothis virescens</i> , 6) <i>Heliothis virescens adulta</i> , 7) <i>Spodoptera frugiperda</i> , 8) <i>spodoptera frugiperda adulta</i> , 9) Não Praga, 10) <i>Pseudoplusia includens</i>	46
Figura 4.3 – Matriz de confusão gerada pelo classificador ResNet-34, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) <i>Anthonomus grandis</i> , 2) <i>Aphis gossype</i> , 3) <i>Helicoverpa amigera</i> , 4) <i>Helicoverpa amigera adulta</i> , 5) <i>Heliothis virescens</i> , 6) <i>Heliothis virescens adulta</i> , 7) <i>Spodoptera frugiperda</i> , 8) <i>spodoptera frugiperda adulta</i> , 9) Não Praga, 10) <i>Pseudoplusia includens</i> , 11)	47
Figura 4.4 – Matriz de confusão gerada pelo classificador ResNet-34*, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) <i>Anthonomus grandis</i> , 2) <i>Aphis gossype</i> , 3) <i>Helicoverpa amigera</i> , 4) <i>Helicoverpa amigera adulta</i> , 5) <i>Heliothis virescens</i> , 6) <i>Heliothis virescens adulta</i> , 7) <i>Spodoptera frugiperda</i> , 8) <i>spodoptera frugiperda adulta</i> , 9) Não Praga, 10) <i>Pseudoplusia includens</i> , 11).	48

- Figura 4.5 – Matriz de confusão gerada pelo classificador ResNet-50, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) Não Praga, 10) *Pseudoplusia includens*, 11). 49
- Figura 4.6 – Matriz de confusão gerada pelo classificador LBP-SVM, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) Não Praga, 16) *Pseudoplusia includens*. 52
- Figura 4.7 – Matriz de confusão gerada pelo classificador AlexNet, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) Não Praga, 16) *Pseudoplusia includens*. 53
- Figura 4.8 – Matriz de confusão gerada pelo classificador ResNet-34, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) Não Praga, 16) *Pseudoplusia includens*. 54
- Figura 4.9 – Matriz de confusão gerada pelo classificador ResNet-34*, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) Não Praga, 16) *Pseudoplusia includens*. 55

Figura 4.10–Matriz de confusão gerada pelo classificador ResNet-50, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) <i>Alabama argillacea</i> , 2) <i>Anthonomus grandis</i> , 3) <i>Aphis gossype</i> , 4) <i>Bemisia tabaci</i> , 5) <i>Helicoverpa amigera</i> , 6) <i>Helicoverpa amigera adulta</i> , 7) <i>Heliothis virescens</i> , 8) <i>Heliothis virescens adulta</i> , 9) <i>Horcias nobilellus</i> , 10) <i>Pectinophora gossypiella</i> , 11) <i>Spodoptera eridania</i> , 12) <i>Spodoptera frugiperda</i> , 13) <i>spodoptera frugiperda adulta</i> , 14) <i>Tetranychus urticae</i> , 15) <i>Não Praga</i> , 16) <i>Pseudoplusia includens</i>	56
Figura 4.11–F-score \hat{f} valores do primeiro experimento: (1º) pragas primárias . . .	57
Figura 4.12–F-score \hat{f} valores do segundo experimentos: (2º) pragas primárias e secundárias do algodão.	58
Figura 4.13–Resultados Comparativos de erro e precisão da ResNet-34*: a) e b) para conjunto de imagens originais, c) e d) conjunto de dados ampliados. . .	61
Figura A.1–Exemplo de imagens de treinamento: a) <i>Alabama argillacea</i> , b) <i>Anthonomus grandis</i> , c) <i>Aphis gossypi</i> , d) <i>Bemisia tabaci</i> , e) <i>Helicoverpa armigera</i> f) <i>Helicoverpa amigera adulta</i> , g) <i>Heliothis virescens</i> , h) <i>Heliothis virescens adulta</i> , i) <i>Horcias nobilellus</i> , j) <i>Pectinophora gossypiella</i> , k) <i>pseudoplusia Includens</i> , l) <i>Spodoptera eridania</i> , m) <i>Spodoptera frugiperda</i> , n) <i>Spodoptera frugiperda adulta</i> , o) <i>Tetranychus urticae</i> e n) <i>Não Praga</i>	69

Lista de Tabelas

Tabela 1 – Número de imagens originais por classe de inseto do banco de imagens.	24
Tabela 2 – Quantitativo de imagem originais e ampliadas para cada classe do conjunto de dados.	24
Tabela 3 – Desempenho (precisão) de cada modelo por classe (%): primária e não pragas.	50
Tabela 4 – Desempenho (precisão) de cada modelo por classe (%): Todas as pragas e não praga.	51

Lista de Algoritmos

Algorithm 1 – Processo de treinamento das RNCs	37
Algorithm 2 – Algoritmo de Abordagem Varredura	38

Lista de Abreviaturas e Siglas

<i>RGB</i>	<i>Red Green Blue</i>
<i>SVM</i>	Máquina de vetores de Suporte (<i>Support Vector Machine</i>)
<i>RNAs</i>	Redes Neurais Artificiais
<i>RNA</i>	Rede Neuronal Artificial
<i>RNC</i>	Rede Neuronal Convolutcional
<i>RNCs</i>	Redes Neurais Convolutcionais
<i>GPU</i>	Unidade de Processamento Gráfico
<i>HOG</i>	Histograma de Gradiente Orientado (<i>Histogram of Oriented Gradients</i>)
<i>MIP</i>	Manejo Integrado de Pragas
<i>SIFT</i>	Transformação de Recurso Invariante de Escala (<i>Scale-Invariant Feature Transform</i>)
<i>MKL</i>	Aprendizado de Múltiplo Núcleo (<i>Multiple Kernel Learning</i>)
<i>RBF</i>	Função de Base Radial (<i>Radial Basis Function</i>)
<i>LBP</i>	Padrões Binários Locais (<i>Local Binary Patterns</i>)
<i>PNG</i>	<i>Portable Network Graphics</i>
<i>2D</i>	Espaço Bidimensional
<i>3D</i>	Espaço Tridimensional
<i>ILSVRC</i>	<i>ImageNet Large Scale Visual Recognition Challenge</i>

Lista de Símbolos

p	Probabilidade de escolha
C	Fator de regularização
R	Raio de binarização
V	Número de vizinho no raio de binarização

1 Introdução

A cultura do algodão (*Gossypium sp.*) é de grande relevância socioeconômica para o Brasil, sendo o país um dos maiores produtores mundiais dessa cultura. Entretanto, as pragas representam um dos elementos limitadores na sua produção agrícola e afetam severamente o crescimento das culturas, pois sobrecarregam os custos de produção (SILVA et al., 2013), bem como podem afetar produtividade e qualidade. Assim, todos os anos, as pragas têm causado perdas significativas em escala global, o que ressalta a importância da identificação correta e da aplicação de medidas de controle direcionadas mais especificamente às categorias de pragas (MARTINEAU et al., 2017).

A classificação visual de insetos é um problema originalmente tratado por biólogos, no entanto, com peculiaridades próprias e desafiadoras para tratamento digital por técnicas em Visão Computacional e Reconhecimento de Padrões. O problema pode ser definido com base em uma fotografia (i.e. imagem digital), ou seja, é possível dizer se há um inseto mostrado nela e, caso haja, especificar à qual espécie ele pertence. De acordo com Chapman (CHAPMAN et al., 2009) a taxonomia é uma tarefa imensa e laboriosa, pois estimam-se mais de 5 milhões de espécies de insetos no mundo. As variações de fundo e objetos adicionam variabilidade de cor, pose, textura, deformações geométricas como aspectos adicionais de incerteza para a tarefa de reconhecimento. Este tem sido um tópico de pesquisa desafiador e está se tornando acessível com a disponibilidade de câmeras digitais de alta resolução e de novos algoritmos para a classificação de padrões e aprendizagem de máquinas (LECUN; BENGIO; HINTON, 2015).

O processo de classificação automática supervisionado fixa uma regra com base em um vetor de variáveis, o qual relaciona o grupo a que as observações pertencem. Os métodos de classificação mais conhecidos e mais antigos em estatística são regressão logística e análise discriminante (EFRON, 1975). Esses métodos possuem baixo custo computacional e regras facilmente interpretáveis, no entanto suas suposições paramétricas frequentemente tornam difícil a aplicação dessas técnicas em casos complexos. São exemplos dessas características vetores de descrição, cor, forma e textura, obtidos por meio de segmentação, podem ser vantajosos quando comparados com descritores construídos manualmente. Entretanto, em casos de técnicas como SVM (*Support Vector Machine*), tais características extraídas podem não atender as expectativas, devido à variabilidade nas imagens, e assim podem não entregar o desempenho esperado.

Nesse contexto, a aprendizagem de máquina é definida como um conjunto de métodos que podem detectar e inferir, de forma automática, certos padrões em um conjunto de dados de treinamento (CHENG et al., 2017). Se o pré-processamento de características não for conduzido, os métodos tradicionais de classificação de aprendizagem de máquina, como as máquinas de suporte vetorial e a rede neuronal padrões típicas, muitas vezes, não conseguem atingir taxas de precisão satisfatórias (LIM; KIM; KIM, 2017). O ambiente das terras agrícolas é complexo, portanto, sistematicamente, é difícil selecionar características gerais que sejam adequadas para todas as pragas-alvo. No entanto, os métodos acima são mais influentes na seleção de características, portanto, na maioria das vezes é difícil integrar em campos agrícolas.

De acordo com Cheng (2017) nos últimos dois anos, a tecnologia de aprendizagem profunda vem se desenvolvendo rapidamente (CHENG et al., 2017). Redes neurais convolucionais profundas (RNCs) têm sido aplicadas ao campo do reconhecimento de objetos em imagens, como a detecção de veículos (CHEN et al., 2014), reconhecimento de movimento humano (JI et al., 2012), em que obteve ótimos resultados. As Redes Neurais Convolucionais (RNCs) têm a capacidade de extrair automaticamente atributos de imagem e, conseqüentemente, podem ser usadas como uma ferramenta de extração de características gerais e aplicada à identificação e classificação de pragas no ambiente de terras agrícolas.

As Redes Neurais Convolucionais são uma forma especial de redes neurais que geralmente obtêm o melhor desempenho em tarefas relacionadas ao reconhecimento de imagens (GOODFELLOW; BENGIO; COURVILLE, 2016). Elas reutilizam mais parâmetros do modelo que redes neurais convencionais e são altamente paralelizáveis, e de maior eficiência nas tarefas que envolvem extrair informações de uma imagem. Martineau et. al. (MARTINEAU et al., 2017), pesquisou quarenta e quatro abordagens baseadas em imagem de classificação de insetos mais recentes da literatura. A maioria das imagens usadas foi baseada em laboratório, tendo apenas três trabalhos relatados que fazem o uso de imagens baseadas em campo. As condições de aquisição desempenham um papel importante para a tarefa, porque as imagens em campo aberto mostram variações maiores em planos de fundo, iluminação natural, poses de insetos, densidade e deformações do que as baseadas em laboratório. Além disso, considerar a árvore da taxonomia descendo de ordem para classificação de espécies precisa de maior precisão, e para efetivamente agir, a classificação de espécies seria importante.

A planta de algodão (*Gossypium sp.*) produz uma fibra macia que é usada para indústrias de vestuário em todo o mundo. Seu comércio está listado entre os dez produtos agrícolas mais comercializados diariamente. O algodão é cultivado em mais de 100 países, ocupando 2,5% da terra arável do mundo (CO-OPERATION; DEVELOPMENT, 2016). Sua produção é em áreas tropicais e subtropicais, com temperaturas variando de 11º a 25º Celsius, e seu ciclo de crescimento desde a semeadura até a maturidade é de 160 a 180 dias. Como é normal nos produtos agrícolas, as pragas podem ser uma grande

preocupação para as plantações de algodão, pois afetam seus rendimentos em quase 40% se não forem manejadas adequadamente. Portanto, a identificação precoce e precisa de pragas diretamente nos campos de algodão seria um benefício substancial para o manejo sustentável das culturas.

Outrossim, a incidência e consequências relacionadas a uma determinada praga de algodão variam conforme cada país. Neste trabalho, quinze principais pragas são consideradas danosas para plantas de algodão (MONSANTO, 2015). Como pragas primárias, encontram-se: *Anthonomus grandis*, *Aphis gossypii*, *Helicoverpa armigera*, *Heliothis virescens*, *Pseudoplusia includens* e *Spodoptera frugiperda*. Como pragas secundárias, estão *Alabama argillacea*, *Bemisia tabaci*, *Horcias nobilellus*, *Pectinophora gossypiella*, *Spodoptera eridania* e *Tetranychus urticae*. As fases adultas de *Helicoverpa armigera*, *Heliothis virescens* e *Spodoptera frugiperda* foram incluídas e consideradas como classes diferentes devido à diferenciação visual e importância. De todas as pragas *Anthonomus grandis* pode ser a de mais uma alta prioridade para identificar, uma vez que sua ocorrência em uma plantação de algodão pode causar danos mais severos em várias fases do ciclo das plantas de algodão.

Em Visão Computacional as tarefas de reconhecimento e classificação de objetos ganharam alta aplicabilidade e precisão com as Redes Neurais Convolucionais (RNCs) e Aprendizagem Profunda (LECUN; BENGIO; HINTON, 2015). Uma RNC padrão típica, por exemplo, é composta de uma série de estágios, combinando camadas convolucionais, de retificação não linear e de agrupamento em sequência, para extrair e selecionar recursos hierarquicamente e, finalmente, um classificador para decisão. Um algoritmo de retropropagação, como o Adam (KINGMA; BA, 2014) é usado para ponderar a aprendizagem e, embora as arquiteturas massivas precisem de uma quantidade substancial de treinamento para otimizar seus pesos, os esquemas de ajuste fino permitem importar pesos iniciais treinados com um grande conjunto de dados semelhantes (por exemplo, ImageNet(KRIZHEVSKY; SUTSKEVER; HINTON, 2012)) e projetar classificador apenas no conjunto de problemas de dados (LECUN; BENGIO; HINTON, 2015).

Assim, o objetivo geral deste trabalho é analisar o desempenho das redes neurais convolucionais no processo de reconhecimento de pragas primárias e secundárias do ecossistema do algodão. Os objetivos específicos são construir um conjunto de imagens de pragas de campo e propor um classificador para tal tarefa, comparando métodos clássicos com as redes neurais convolucionais, e propondo modificações. Para entender a problemática na qual se enseja esta dissertação, deve-se mencionar que a produtividade brasileira de algodão apresenta-se próxima àquelas alcançadas pelos principais países produtores (ALVES; BARROS; BACCHI, 2008). Não obstante, um dos principais fatores que impedem a expansão do algodoeiro no país são as perdas advindas do ataque de pragas (MIRANDA; SUASSUNA, 2004). O algodoeiro é considerado uma cultura altamente atacada por uma ampla variedade de insetos-praga que ocasionam perdas à produção (MIRANDA; SUASSUNA, 2004; RAMALHO; JESUS et al., 1988), além de gerarem gastos

adicionais para seu controle. Dessa forma, a situação atual da cotonicultura nacional exige um alto nível de conhecimentos pelos cotonicultores, de modo que os seus lucros ou prejuízos, em cada ano agrícola, dependem principalmente da sua eficiência na luta contra as pragas e da preservação do meio ambiente (SILVA et al., 2013).

O reconhecimento de uma praga é a etapa preliminar para resolver qualquer objeção entomológica na agricultura, o que possibilita a obtenção de toda a informação bibliográfica sobre ela (MARTINEAU et al., 2017). Apesar da relevância da taxonomia, os técnicos agrícolas geralmente não se preocupam em conhecer os caracteres taxonômicos, considerando a identificação como tarefa exclusiva dos especialistas (MARTINEAU et al., 2017). Tal atitude é até compreensível, visto que a identificação é uma atividade difícil e desestimulante para os não-especialistas. Fatores como a existência de um enorme número de diferentes espécies, a escassez de informação biológica, a complexidade de identificação disponíveis na literatura e a dificuldade na interpretação dos termos técnicos pela ausência de ilustrações justificam como é trabalhoso o processo de identificação de pragas. Assim, as redes neuronais mostraram-se bons classificadores para problemas linearmente separáveis (EBRAHIMI et al., 2017). Ao lidar com problemas de classificação de imagem, os modelos mais avançados são de redes neuronais convolucionais restringidos por sua arquitetura (HE et al., 2016). As redes neuronais mais profundas eram difíceis de se treinar, em virtude da falta de recursos computacionais e de indisponibilidade de bases de dados com volumes suficientes para sua utilização (MARTINEAU et al., 2017). Assim, as primeiras redes neuronais geralmente continham poucas camadas ocultas. Nos últimos anos, o rápido aumento do desempenho do computador e a introdução da computação auxiliada por unidade de processamento gráfico (GPU) possibilitaram a construção e o treinamento de modelos de Redes Neuronais Convolucionais (RNCs) (LECUN et al., 1998; GOODFELLOW; BENGIO; COURVILLE, 2016). Um sistema de classificação de pragas de maneira livre, por meio de imagens e treinamento de redes neuronais convolucionais, pode ser utilizado para identificação de pragas potencialmente prejudiciais à agricultura, a fim de detectar os principais agentes causadores de danos econômicos e perdas no cultivo do algodão (ALVES; BARROS; BACCHI, 2008). Assim, pretende-se consolidar respostas para o seguinte problema: “Quais as principais vantagens que um sistema baseado em aprendizagem profunda pode trazer para a classificação das principais pragas do algodoeiro por imagem?”

A fim de justificar a busca pela remediação da problemática em questão, salienta-se que as pragas agrícolas já representaram até 40% de perdas no crescimento das culturas e o armazenamento de produtos agrícolas (CO-OPERATION; DEVELOPMENT, 2016). Todos os anos, essas pragas causam perdas significativas em escala global. O cenário atual da cotonicultura exige um elevado nível de conhecimento pelos cotonicultores, de modo que os seus lucros ou prejuízos, em cada ano de colheita, passe a depender principalmente da sua eficiência na luta contra as pragas e da preservação do meio ambiente. Nos últimos anos, a agricultura de precisão vem se desenvolvendo rapidamente, e cada vez mais é

comum o uso de câmeras nas terras agrícolas, com isso, as imagens de pragas agrícolas começam a ser mais acessíveis (CHENG et al., 2017).

O reconhecimento de objetos, baseado em Visão Computacional, pode efetivamente reduzir os custos com reconhecimento, velocidade e eficiência, sendo a automatização potencial significativo de melhoria. Além disso, os métodos automatizados para a classificação de insetos são essenciais para não-especialistas. Classificações de insetos no campo de Visão Computacional caracterizam um tópico de pesquisa interessante. Um dado comum, que pode ser usado nesse contexto, é uma imagem cuja identificação é feita por meio da descrição baseada na imagem via sistema de classificação. Os sistemas de classificação de imagens que usam modelos de classificação tradicionalmente artesanais são baseados no histograma de gradiente orientado (HOG) e na máquina de vetores de suporte (SVM) (LIM; KIM; KIM, 2017).

A identificação de insetos é um dos processos fundamentais de coleta e gerenciamento de informações biológicas de espécies de insetos. Tradicionalmente, ela é baseada em diagnóstico morfológico fornecido por estudos taxonômicos. Somente especialistas como taxonomistas e técnicos qualificados podem identificar com precisão os insetos, porque requer especial conhecimento adquirido através de uma rica experiência (LIM; KIM; KIM, 2017).

Nesse ínterim, as Redes Neurais Artificiais (RNAs) podem ser consideradas uma alternativa baseada em conceito de computação com o objetivo de trabalhar com processamento de dados de forma semelhante ao cérebro humano, por meio da aquisição de conhecimento e por meio da experiência, além de prever e reconhecer padrões ou estabelecer grupos (XU et al., 2018). O atributo principal da rede neuronal artificial (RNA) é a estrutura não linear, ligada a uma capacidade de não requerer informações detalhadas sobre os processos físicos do sistema (SINGH; MOHSIN; MASOOD, 2018). O método de classificação apresenta vantagens, como não paramétrico e tolerante à perda de dados (XU et al., 2018).

Além disso, métodos de aprendizagem profunda, como a Rede Neuronal Convolutiva (RNC), demonstraram ser eficazes no reconhecimento de espécies de pragas (HSU; LEE; CHEN, 2011). As RNCs apresentam vantagens sobre os métodos tradicionais de aprendizagem de máquina, porque não requer a extração de recursos de imagem. Uma das peculiaridades da RNC é a capacidade em extrair as características das imagens de entrada sem necessidade de um pré-processamento destas. Quanto mais camadas de convolução, mais características são extraídas.

A RNC tem a capacidade de extrair automaticamente recursos de imagem, portanto, pode ser usada como uma ferramenta de extração de recursos gerais e aplicada na identificação de pragas no ambiente de terras agrícolas.

Para controlar essas pragas, o agricultor geralmente utiliza-se da aplicação de inseticidas químicos de forma inadequada, que ocasiona danos ao meio ambiente e à saúde

do agricultor. No entanto, pode-se reduzir o efeito negativo desses inseticidas, por meio da utilização do Manejo Integrado de Pragas (MIP), o qual é constituído de várias estratégias de controle. Todavia, para o sucesso no emprego dessas estratégias, é necessário que se façam amostragens para a determinação dos níveis de controle das pragas e da ação dos inimigos naturais, a fim de otimizar a utilização de inseticidas (SILVA et al., 2013). Na agricultura, a identificação de insetos e pragas em geral, nas plantações, auxilia nas decisões de métodos de controle e estimativas de danos. Monitorar os campos de plantação com câmeras de mão seria um método eficiente de inspeção, especialmente se algoritmos pudessem ser mostrados tão precisos quanto possível em um processo de classificação automatizado, baseado nessas imagens.

Vale ressaltar que o ecossistema algodoeiro engloba extensa diversidade de artrópodes, e os levantamentos dessa fauna na cultura, realizados mundialmente, indicam que o número de 108 espécies (FERNANDES; BUSOLI; DEGRANDE, 1999) encontradas pode variar desde algumas poucas centenas a mais de mil, e o maior número dessas espécies são predadoras. Estima-se que o número de espécies pragas esteja entre 20 e 60, mas prejuízos significantes na cultura podem ser causados por aproximadamente 16 espécies pragas, na maioria dos sistemas de produção do algodão (MONSANTO, 2015).

Quanto ao reconhecimento de pragas de algodão a partir de imagens de campo, poucos resultados foram relatados na literatura. Há a proposição da extração de 10 formas morfológicas de imagens binárias segmentadas de doze (12) classes de insetos comumente presentes em plantações de algodão (GASSOUMI; PRASAD; ELLINGTON, 2000). Uma abordagem de árvore de decisão com Redes Neurais Artificiais (RNA) para cada classe é mostrada para realizar o reconhecimento de insetos. No entanto, o número de imagens utilizadas não foi mencionado. Além disso, estado da arte, em muitas tarefas de reconhecimento de objeto visual, desde 2014, envolve aprendizagem profunda (LECUN; BENGIO; HINTON, 2015).

Portanto, este trabalho justifica-se não somente pela necessidade do desenvolvimento de pesquisas na área, como também pelas contribuições de ordem prática que um sistema de reconhecimento de pragas por imagem pode trazer para os proprietários de lavouras de algodão.

1.1 Objetivos

Desenvolver e testar um classificador de pragas de algodão, usando imagens de campo como entrada. Para tanto, será necessário também coletar e organizar um banco de imagens apropriado com separação de categorias de pragas primárias e secundárias. O classificador será baseado em aprendizagem de máquinas pois a variabilidade dos objetos em imagens (i.e. insetos em imagens de campo) é muito grande para uma solução analítica. Técnicas de Aprendizagem Profunda serão testadas e aprimoradas para o problema

apresentado, com possibilidades de extensão.

1.2 Metodologia de pesquisa

Estruturação de um banco de imagens de pragas de campo pertencente à cultura do algodão;

Integração do banco de imagens de pragas para uso em Aprendizagem de Máquinas, através de indexação e seleção por aleatoriedade para extração de características (treinamento e validação), seja para técnicas SVM, seja para Redes Neurais Convolucionais por alimentação direta (feedforward) e residuais;

Experimentação e Avaliação dos resultados.

1.3 Organização do trabalho

O Capítulo 2 apresenta os principais conceitos teóricos utilizados para compreender o manejo integrado de pragas, pragas do algodoeiro, classificação de imagem, métodos de extração de padrões, redes neurais convolutivas e os processos atualmente empregados para classificação de pragas na cultura do algodão.

O Capítulo 3 apresenta a metodologia empregada na organização de um conjunto de dados de imagem de pragas primárias e secundárias para a culturas de algodão, na integração do banco de imagens de pragas com as redes neurais clássicas e as redes residuais profundas, no processo de treinamento das redes neurais e o uso dos modelos de redes neurais convolucionais, no intuito de demonstrar os resultados comparativos de classificação para outros modelos de redes, como AlexNet, ResNet-34, ResNet-50 e Resnet-34*.

O Capítulo 4 apresenta a abordagem realizada neste trabalho no intuito de resolver dois diferentes problemas de classificação. O primeiro refere-se a um conjunto de seis pragas primárias *versus* imagem de plantação de algodão sem pragas. O segundo refere-se a uma tarefa de classificação de dezesseis classes, composta por espécies de pragas primárias e secundárias, mais uma classe de imagens de plantação sem pragas.

O Capítulo 4.2 mostra a análise dos resultados obtidos no Capítulo 4 em relação aos testes de classificação utilizando um modelo de classificador clássico (LBP-SVM) *versus* modelos de redes neurais convolucionais (AlexNet, Resnet-34, Resnet-50 e Resnet-34*) em um conjunto de dados de imagens de pragas de campo da cultura do algodão.

O Capítulo 5 traz as conclusões do trabalho quanto aos objetivos alcançados, a avaliação da metodologia desenvolvida, bem como as as contribuições científicas para trabalhos e pesquisas futuras.

2 Revisão Bibliográfica

Este capítulo revisa os principais trabalhos sobre classificação de pragas do algodoeiro usando imagens, bem como explicita o problema tanto do ponto de vista do manejo das pragas do algodoeiro como de técnicas de classificação.

2.1 Pragas em Lavouras

O Manejo Integrado de Pragas (MIP) tem como objetivo a adoção de estratégia de controle múltiplo de infestações e de medidas preventivas e corretivas que tangem ao controle ecológico, assim, deve-se pensar inicialmente por um enfoque que relacione o equilíbrio biológico das pragas com os seus inimigos naturais e os níveis de danos econômicos, ou seja, se o custo de controle será inferior ao dano provocado pela praga. Assim, a estratégia não é eliminar os insetos-pragas, mas reduzir sua população de modo a permitir que seus inimigos naturais permaneçam na plantação agindo sobre suas presas, favorecendo a volta do equilíbrio natural desfeito pela plantação e pelo uso de defensivos agrícolas (SILVA *et al.*, 2013). Consequentemente, é de grande relevância que o produtor saiba reconhecer as pragas e seus inimigos naturais, para que possam compreender o agroecossistema e, assim, empregar com eficiência as formas de controle disponíveis.

A identificação de insetos vivos em imagens, particularmente a classificação de espécies, é uma tarefa importante, que precisa ser resolvida em muitas situações. Na agricultura, a identificação de insetos e pragas em geral, nas plantações, auxilia nas decisões de métodos de controle e de estimativas de danos. Monitorar os campos de plantação com câmeras de mão seria um método eficiente de inspeção, especialmente se algoritmos pudessem ser mostrados tão precisos quanto possível em um processo de classificação automatizado, com base nessas imagens.

2.2 Pragas do Algodoeiro

São consideradas principais pragas da cultura do algodão aquelas que afetam os botões florais, que são classificadas como pragas primárias. Já as pragas de importância secundárias são aquelas que atacam as folhas, caules e sementes plantadas (FERNANDES;

BUSOLI; DEGRANDE, 1999), as diferentes fases de ataque das principais pragas do algodoeiro pode ser visualizadas na Figura 2.1.

Um dos aspectos restritivos a expansão do algodoeiro no país é o ataque de pragas e perdas provenientes. Isso porque o algodoeiro é uma cultura altamente atacada por uma ampla variedade de insetos-praga, que ocasionam perdas à produção, além de gerarem gastos adicionais para seu controle (SILVA et al., 2013). Dentre as pragas que infestam a cultura, existem aquelas denominadas pragas indiretas (que atacam outras partes da planta que não aquela que será comercializada) e as pragas diretas (que atacam diretamente a estrutura que será comercializada – o fruto). A depender da severidade do ataque dessas pragas diretas, perdas consideráveis à produção podem ser verificadas. Surtos de população dessas pragas são apontados como fonte de maiores prejuízos nas lavouras, e em cada região há uma maior predominância de uma ou mais pragas. Em algumas regiões, elas são originárias de outras culturas e afetam, também, o algodoeiro.

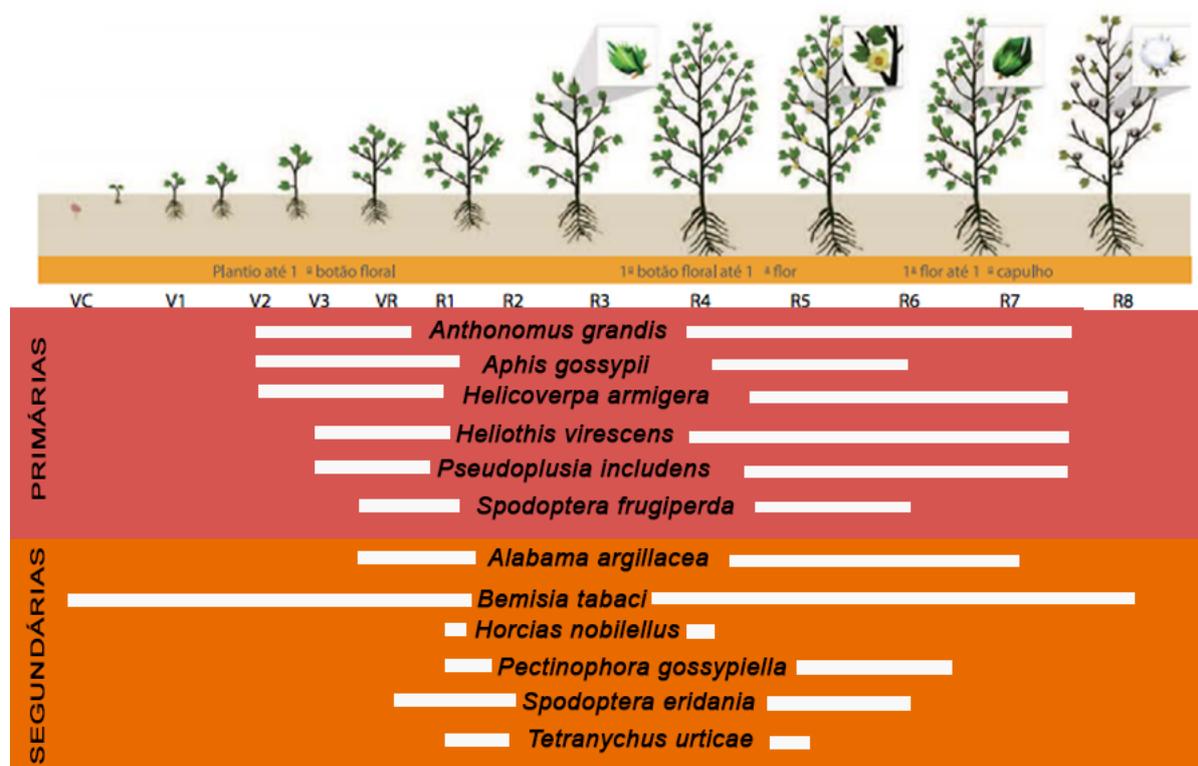


Figura 2.1 – Pragas primárias do algodão em seus diferentes estádios. Adaptado de (MONSANTO, 2015)

Neste trabalho, doze pragas mais comuns são consideradas danosas para plantas de algodão. Como pragas primárias, encontram-se *Anthonomus grandis*, *Aphis gossypii*, *Helicoverpa armigera*, *Heliothis virescens*, *Pseudoplusia includens*, e *Spodoptera frugiperda*, que é considerada um nova mutação. Como pragas secundárias, encontram-se *Alabama argillacea*, *Bemisia tabaci*, *Horcias nobilellus*, *Pectinophora gossypiella*, *Spodoptera eridania* e *Tetranychus urticae*. As fases adultas de *Helicoverpa armigera*, *Heliothis virescens* e *Spodoptera frugiperda* foram incluídas e consideradas como classes diferentes, devido à

diferenciação visual e à importância, e com isso relacionamos quinze classes diferentes visualmente de pragas. De todas as pragas, *Anthonomus grandis* pode ser considerada de alta prioridade para se identificar, uma vez que sua ocorrência em uma plantação de algodão pode causar danos mais severos em várias fases do ciclo das plantas de algodão.

2.2.1 *Anthonomus grandis*

É conhecido popularmente como Bicudo, em sua fase adulta são pequenos besouros, com cerca de 4 a 9 mm de comprimento e 7 mm de envergadura, caracterizados por apresentarem coloração acinzentada ou castanha, com aparelho bucal mastigador em forma de tromba. A fêmea de *Anthonomus grandis* deposita a maioria dos seus ovos dentro dos botões florais de tamanho médio (com diâmetro > 3 mm e < 6 mm) (SILVA et al., 2013; MONSANTO, 2015), desde o aparecimento dos primeiros botões florais na planta até o final do ciclo da cultura (RAMALHO; JESUS et al., 1988). Os botões florais são as estruturas preferidas para alimentação e oviposição pelo bicudo; embora, no final do ciclo da cultura, as fêmeas depositam os ovos tanto em botões florais como em maçãs jovens. As características de danos causados são botões florais abertos e amarelados, com presença de perfurações escuras (orifícios de alimentação) ou com pólen aderido (orifícios de oviposição) (MIRANDA; SUASSUNA, 2004), sendo que, internamente, as fibras e sementes são destruídas pelas larvas, que impedem sua abertura normal (“carimã”), deixando-as enegrecidas (RAMALHO; JESUS et al., 1988).



Figura 2.2 – Imagens de *Anthonomus grandis*

2.2.2 *Aphis gossypii*

O *Aphis gossypii* são insetos pequenos, tamanho de 1 a 1,8 mm, coloração variável entre os tons amarelo e verde escuro, como poder ser visto na figura 2.3. Conhecidos popularmente como pulgão, situam-se na parte inferior das folhas e nos brotos novos das plantas (MIRANDA; SUASSUNA, 2004), do qual sugam constantemente a seiva. Têm alta capacidade reprodutiva. Nas condições climáticas do nosso país, a reprodução ocorre exclusivamente por partenogênese telítica (somente há produção de fêmeas) (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013).



Figura 2.3 – Imagens de *Aphis gossypii*.

2.2.3 *Helicoverpa armigera*

Helicoverpa armigera é uma lagarta identificada recentemente, que tem surpreendido produtores e pesquisadores pelo mundo, ela ataca diversas culturas e, em virtude do seu poder de destruição, e causa prejuízos, principalmente, às lavouras de milho, soja e algodão (MONSANTO, 2015). A sua entrada é realizada pelas vias aéreas (flor, folha, gemas, fruto/vagem, estruturas reprodutivas e pontos de crescimento) da planta. Nos estágios imaturos, as lagartas alimentam-se em todos os estágios de desenvolvimento da planta, danificando todas as estruturas, como podemos ver na Figura 2.4 (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013).



Figura 2.4 – Imagens de *Helicoverpa armigera*.

2.2.4 *Heliothis virescens*

Essa praga em seu estado larval pode alcançar até 25mm de comprimento. Sua coloração alterna entre o verde, rosa e o amarelo, com a presença de pontos escuros com microespinhos no dorso. Em fase adulta, são mariposas com asas anteriores de coloração esverdeada e apresentam três faixas transversais avermelhadas, possuem 28 a 35mm de envergadura. A coloração de suas asas é esbranquiçada, com uma faixa cruzada no centro. Os danos provocados na cultura do algodão são caracterizados pelos ataques aos botões florais e às maçãs, o que causa a queda de ambos. O período de maior ataque da praga ocorre entre 70 e 120 dias de existência da planta, e a mariposa ovípara mais na fase de lua nova, quando as noites são mais escuras. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013).



Figura 2.5 – Imagens de *Heliothis virescens*.

2.2.5 *Pseudoplusia includens*

É um praga de fácil identificação por possuir apenas dois pares de falsas pernas no meio do corpo e não quatro pares, como verificado na maioria das lagartas. A lagartas são verdes, com uma linha dorsal de coloração branca. Deslocam-se de forma semelhante às lagartas conhecidas como “mede-palmos” e, após seu completo desenvolvimento, tecem um fino casulo de seda, no interior do qual se transformam em pupa, tendo, a princípio, a coloração verde-brilhante e, posteriormente, marrom-escura. O seu ataque incide nas folhas das plantas. Em sua fase adulta, possui asa acinzentada, com estigma e mácula prateados, contornados de marrom escuro brilhante e podem viver em média de 10 a 12 dias. As fêmeas depositam 300 a 600 ovos, colocados isoladamente tanto sobre a face inferior como superior da folha, e apresentam coloração verde. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013).



Figura 2.6 – Imagens de *Pseudoplusia includens*.

2.2.6 *Spodoptera frugiperda*

)

Em sua fase larval, inicialmente possuem uma coloração que vai de branco-cremosa a esverdeado, com cabeça e pelos pretos. Possui três pares de pernas no tórax e cinco pares de falsas pernas no abdome e, nos últimos estágios de vida, podem atingir 50 mm. A fase larval pode variar de 20 a 30 dias e, quando já estão completamente desenvolvidas, as lagartas de *Spodoptera frugiperda* param de alimentar-se e deslocam-se para o solo, construindo a câmara pupal. A pupa mede cerca de 15 mm de comprimento, tem coloração avermelhada ou amarronzada. É um inseto de hábito noturno, podendo colocar cerca de 100 ovos na parte superior da folha das plantas. Na fase adulta, medem cerca de 35 mm de envergadura, a coloração das asas anteriores é pardo-escuro e das posteriores,

branco-acinzentada. A durabilidade do adulto é de cerca de 12 dias, e o ciclo completo da praga é pouco mais de 30 dias. Seus danos se dão ao raspar as folhas, maçãs e botões florais, e, quando desenvolvidas, as lagartas perfuram a base das maçãs, causando o sintoma de "coração morto". (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013)



Figura 2.7 – Imagens de *Spodoptera frugiperda*.

2.2.7 *Alabama argillacea*

Essa espécie apresenta uma característica observada, tais lagartas atacam as folhas das plantas, devorando-as quase totalmente. Elas podem medir até 40 mm de comprimento, com coloração que varia do verde-amarelado ao verde-escuro. Apresenta a cabeça amarelada com pontuações pretas e listras longitudinais ao longo do corpo. Ao passar o período larval, as lagartas dobram os bordos das folhas, prendendo-os com fios de seda, e se abrigam ali, para se transformarem em pupa. A mariposa exprime hábito noturno, apresenta um tamanho de aproximadamente de 30 mm de envergadura, possui cor marrom-palha e exibe duas manchas circulares escuras na parte central das asas anteriores. Os ovos são muito pequenos, de coloração azul-esverdeada, quando recém colocados, mas tornam-se transparentes à medida que se aproximam da eclosão. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013)



Figura 2.8 – Imagens de *Alabama argillacea*.

2.2.8 *Bemisia tabaci*

É um inseto-praga que possui amplo espectro de hospedeiros e causa prejuízos em diversas culturas de importância econômica no Brasil, dentre elas, a soja. Na sua fase adulta, medem de 1 a 1,2 mm de comprimento, sendo o macho ligeiramente menor. O corpo dos adultos possuem dorso amarelados e estes apresentam dois pares de asas de

coloração branca. A reprodução pode ser sexuada e assexuada, e, neste último caso, apenas machos são produzidos. Os adultos se alimentam na face abaxial das folhas novas das plantas, onde realizam a postura de ovos que, posteriormente, darão origem às ninfas, estas permanecem fixas debaixo dos folíolos. Em virtude dos ataques, pode ocorrer queda prematura de folhas, como também de botões e maçãs, decorrentes do hábito sugador do inseto, que causa amarelecimento do limbo foliar e pontuações, provocando envelhecimento precoce das folhas, devido à injeção de saliva tóxica. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013)



Figura 2.9 – Imagens de *Bemisia tabaci*.

2.2.9 *Horcias nobilellus*

Sua forma em estado de ninfas e adultas são parecidas. As ninfas apresentam um “Y” invertido sobre o abdome de cor avermelhada, apresentam manchas pretas e amarelas pelo corpo e os adultos têm um “V” característico de cor amarela. O ciclo biológico tem duração aproximada de 27 a 35 dias, o período de incubação dos ovos fica em torno de 12 dias e o período ninfal dura entre 15 e 20 dias. A sua forma de ataque se dá em sugar os ramos das plantas do algodoeiro, o que provoca a queda de botões florais e de maçãs. As picadas provocam lesões escuras e brilhantes na superfície das cápsulas. Internamente, nódulos são formados, comprometendo a fibra. As maçãs, após o ataque, apresentam-se deformadas e com podridão. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013)



Figura 2.10 – Imagens de *Horcias nobilellus*.

2.2.10 *Pectinophora gossypiella*

Lagartas que podem atingir o comprimento de 12 mm, de coloração branco-leitoso quando pequenas e rosadas quando crescidas. As falsas pernas inseridas entre o terceiro e o

sexto segmento abdominal contêm de 15 a 20 ganchos dispostos em um círculo incompleto, com a abertura voltada para fora. Após completarem o período larval, as lagartas deixam as estruturas atacadas para formar um casulo sedoso, que hospedará a pupa (marrom brilhante), localizando-se, em geral, próximo à superfície do solo. As mariposas fêmeas apresentam uma coloração, em geral, acinzentada ou amarronzada, asas franjadas, com bandas enegrecidas nas asas anteriores e coloração cinza prateada nas asas posteriores, têm hábitos noturnos, escondendo-se na parte basal das plantas ou no solo. Alcançam 8 a 9 mm de comprimento e apresentam envergadura de 15 a 20 mm. O número de ovos depositados varia entre 100 e 500, a depender do tamanho e do período de vida das fêmeas. Os danos causados pelos ataques das lagartas geralmente ocorrem nas maçãs, no intervalo de 10 a 20 dias de idade, pois elas perfuram a região protegida pelas brácteas, que é um orifício de entrada extremamente pequeno. Uma vez dentro das maçãs, é comum verificar-se a formação de um calo no local de ataque. As lagartas alimentam-se das sementes e do conteúdo interno das maçãs jovens. Em consequência do ataque, pode haver queda de botões, injúria às flores, perda total de maçãs pequenas e dano parcial em maçãs mais velhas: tudo isso compromete a produtividade do algodoeiro. (MIRANDA; SUASSUNA, 2004; MONSANTO, 2015)



Figura 2.11 – Imagens de *Pectinophora gossypiella*.

2.2.11 *Spodoptera eridania*

Essas lagartas contêm coloração que pode variar de amarelo-pálido a preto, com listras corpóreas longitudinais e reticulações com formas triangulares. Apresentam características importantes que ajudam na identificação da espécie, como: regiões esclerotizadas localizadas no pronoto e no final do abdome. A fase larval dura entre 15 a 20 dias, as pupas são encontradas no solo, após 8 a 10 dias emergem os adultos que apresentam coloração cinza com envergadura de até 40 mm. Os machos têm um traço preto que se estende até a margem da asa e as fêmeas possuem um ponto preto no centro das asas. A capacidade de oviposição é em torno de 1000 ovos, as posturas são de coloração verde, os ovos são colocados em grupos, geralmente depositados na face inferior das folhas cobertos ou não com escamas brancas. O seu ataque em geral danifica frutificações, impede o desenvolvimento normal das plantas e abre caminho para entrada de fungos que promovem o apodrecimento dos botões florais. (MIRANDA; SUASSUNA, 2004; SILVA et al., 2013)



Figura 2.12 – Imagens de *Spodoptera eridania*.

2.2.12 *Tetranychus urticae*

Esses organismos pequenos, semelhantes a rainhas, de forma ovalada, cor esverdeada e com duas manchas escuras no dorso, são conhecidos também como Ácaros rajados, em virtude de serem esverdeados, com duas manchas escuras de cada lado das costas, porém eles são muito pequenos, mas se consegue vê-los a olho nu. Os ovos do ácaro rajado são amarelos e ficam presos na folha por fios de teia que os adultos tecem, mas, à medida que se aproximam da eclosão das larvas, tornam-se amarelados. São capazes de colonizar todas as porções foliares e frutíferas das plantas de algodão, normalmente são encontrados na parte inferior das folhas. As folhas infestadas por esse ácaro inicialmente tornam-se amareladas. Posteriormente, essas áreas ficam necrosadas, ocorrendo perfurações nas folhas. Sob infestações severas, ocasionam a desfolha precoce, o que afeta a produtividade. (MIRANDA; SUASSUNA, 2004; PEREIRA; ALBUQUERQUE; BASTOS, 2006; SILVA et al., 2013)



Figura 2.13 – Imagens *Tetranychus urticae*.

2.3 Reconhecimento Visual de Pragas

O reconhecimento de uma praga é a etapa preliminar para resolver qualquer objeção entomológica na agricultura, uma vez que possibilita a obtenção de toda a informação bibliográfica sobre a praga. Apesar da relevância da taxonomia, os entomologistas agrícolas geralmente não se preocupam em conhecer os caracteres taxonômicos, considerando a identificação como tarefa exclusiva dos especialistas (MARTINEAU et al., 2017). Tal atitude é até compreensível, visto que a identificação é uma atividade difícil e desestimulante para os não-especialistas. Fatores como a existência de um enorme número de diferentes espécies, a escassez de informação biológica, a complexidade de identificação disponíveis na

literatura e a dificuldade na interpretação dos termos técnicos pela ausência de ilustrações justificam como é trabalhoso o processo de identificação de insetos.

As primeiras propostas de reconhecimento de pragas agrícolas em campo eram manuais, as quais requeriam habilidades humanas para o reconhecimento de possíveis pragas. Gassoumi ([GASSOUMI; PRASAD; ELLINGTON, 2000](#)) utiliza a abordagem *soft computing*, que é distintamente diferente das técnicas de estatística clássicas, para classificar e identificar insetos presentes nos ecossistemas agrícolas, focando especificamente naqueles que comumente habitam nos ecossistemas do algodão. Nesse sistema, o reconhecimento será baseado unicamente em características extraídas de todos os possíveis insetos que possam aparecer no campo de algodão em diversas estações do ano e sob várias condições, e o número de classes de insetos a serem identificadas foi recebido com sucesso. A aparência de insetos no campo agrícola depende muito de parâmetros como condições climáticas, umidade, estação do ano, plantas hospedeiras, tipo de cultura, entre outras variáveis. Uma vez a amostra de insetos coletada, o sistema identificaria ou reconheceria os insetos amostrados em dois grupos fundamentais. Estes poderiam ser classificados como insetos "Desejáveis" e "Indesejáveis". Para "Desejáveis", entende-se os insetos que compreendem as espécies de Controle Biológico; os "Indesejáveis" naturalmente pertencem à espécie de praga. A variação entre os recursos não foi grande o suficiente para projetar uma estrutura de Rede Neuronal Artificial (RNA), capaz de separar todos os insetos de uma só vez. Dessa forma, seria necessário utilizar a árvore de decisão, visto que a abordagem *Soft Computing* utiliza Redes Neurais Artificiais (RNA) para o processo de reconhecimento. O reconhecimento de insetos é um dos processos fundamentais para coletar e gerenciar informações biológicas de espécies de insetos. Tradicionalmente, o reconhecimento de insetos é baseado no diagnóstico morfológico fornecido por estudos taxonômicos ([MARTINEAU et al., 2017](#)). Somente especialistas, como taxonomistas e técnicos especializados, podem reconhecer com precisão as espécies de insetos, porque isso requer conhecimento adquirido ao longo de anos de experiência. Nesse campo, a configuração baseada em laboratório ainda é a configuração mais utilizada, e o posicionamento dos insetos é feito basicamente de forma manual, com uma pose restritiva e ainda há poucos sistemas de reconhecimento de insetos em campo aberto, provavelmente devido a um contexto de reconhecimento mais difícil (fundo desordenado, insetos vivos, entre outros) ([MARTINEAU et al., 2017](#)). Esse tipo de reconhecimento baseado em imagens pode ser visto como uma aplicação de reconhecimento de imagem. Assim, seu desempenho varia de acordo com o método de construção, o conjunto de dados de imagens e o método utilizado para realizar o reconhecimento.

Lim, ([LIM; KIM; KIM, 2017](#)) em seu artigo, reforça que a identificação de insetos é um dos processos fundamentais para coletar e gerenciar informações biológicas de espécies de insetos. Tradicionalmente, a identificação de insetos é baseada no diagnóstico morfológico fornecido por estudos taxonômicos. Somente especialistas, como taxonomistas e técnicos especializados, podem identificar com precisão as espécies de insetos, porque

isso requer conhecimento adquirido ao longo de anos de experiência. Em alguns casos, um técnico pode usar referências morfológicas para realizar a identificação geral, mas, na maioria dos casos, é necessário um taxonomista qualificado. Assim, a velocidade geral de identificação de insetos diminui devido à necessidade de um alto nível de perícia. Como resultado, há uma necessidade de métodos de identificação alternativos e precisos que os não-especialistas possam usar. Todas as redes neurais artificiais aprendem com os dados. Isso vale também para a RNC. Se a qualidade do conjunto de dados de aprendizagem for ruim, a eficiência de aprendizagem não é tanto melhorada. O problema é que não é fácil coletar bons conjuntos de dados. No caso de insetos, há espécies facilmente observáveis em todos os lugares, enquanto outras são observáveis apenas em certas áreas, como montanhas e cavernas em subúrbios urbanos. Além disso, fatores de tempo (como dia e noite ou mudanças sazonais) é, também, uma das dificuldades na coleta de dados (GASSOUMI; PRASAD; ELLINGTON, 2000).

Lim, (LIM; KIM; KIM, 2017) verificou como a configuração do conjunto de dados de imagem e o número de kernels na camada de convolução afetam o desempenho da rede neuronal para o desenvolvimento da RNC de reconhecimento de insetos. O experimento foi conduzido com 27 classes de insetos, do dataset do ImageNet com o AlexNet. Foi constatado que o desempenho de reconhecimento da rede neuronal foi melhorado à medida que o número de núcleos de convolução aumentou, e os insetos reconhecidos apareceram bem ao centro da imagem. Portanto, é um fato comum que o desempenho da reconhecimento mude de acordo com a configuração dos conjuntos de dados de treinamento e teste. Um conjunto de dados qualitativamente bom é muito útil para melhorar o desempenho de treinamento e classificação da rede neuronal. No entanto, não é fácil determinar se uma determinada imagem pode ser um conjunto de dados qualitativamente bom. Dessa forma, percebe-se que o objeto bem representado no centro da imagem é um bom dado e para realização de recorte e redimensionamento de imagem. Como resultado, a classificação do desempenho melhorou por volta de 20% a 25%, com taxa de acerto entre 75,04% a 80% na validação cruzada.

A segmentação de imagens coloridas é usada (FAITHPRAISE et al., 2013) para separar o inseto dos *pixels* esverdeados das folhas em um processo de agrupamento *k-means*. Um filtro de correspondência é, então, treinado com uma variedade do mesmo inseto em diferentes posições rotacionadas em 2D. A correspondência é implementada como uma correlação entre os modelos de um conjunto de dados e cada imagem de entrada segmentada.

Chengjun Xie,(XIE et al., 2015) propôs usar um conjunto múltiplo de características (cor, forma, textura, SIFT, HOG) em um esquema de codificação esparsa, para representar as categorias de imagens de insetos de 24 espécies de diferentes culturas. O aprendizado de múltiplos núcleos (MKL) é, então, aplicado como uma técnica de reconhecimento para fundir e decidir sobre as categorias de insetos em imagens baseadas em campo. Em um treinamento de 60 imagens por categoria e uma média de 25 imagens para testes em cada

categoria, eles relataram 85,5% de precisão de seu método. Em seus conjuntos de dados, insetos foram mostrados em *close-ups*, levando cerca de 85% a 90% da imagem.

O estado da arte em muitas tarefas de reconhecimento visual de objeto desde 2014 envolve o aprendizado profundo (LECUN; BENGIO; HINTON, 2015). São modelos computacionais com múltiplas camadas de processamento, capazes de aprender com os dados, cujas estruturas intrínsecas possibilitam classificar com precisão maior do que os modelos clássicos em situações desafiadoras, como imagens. A análise de imagens e o aprendizado profundo entraram no domínio da agricultura também (KAMILARIS; PRENAFETA-BOLDÚ, 2018). As aplicações mais populares de aprendizado profundo na agricultura estão relacionadas a doenças foliares, reconhecimento de plantas, e estimativas de produtividade. (KAMILARIS; PRENAFETA-BOLDÚ, 2018). O reconhecimento de insetos e pragas começou a ser tratado muito recentemente com redes profundas (LIM; KIM; KIM, 2017), (CHENG et al., 2017). Xi Cheng, (CHENG et al., 2017) abordou o problema de reconhecimento de insetos usando imagens baseadas em campo e modelos de aprendizagem profunda. Eles selecionaram 10 classes de insetos, com 55 imagens por classe (XIE et al., 2015). Os resultados foram fornecidos com um modelo AlexNet e duas redes residuais profundas (ResNet-50, ResNet-101), alcançando precisão de 86,67%, 94,67%, 98,67%, respectivamente, para as 10 espécies de insetos testadas. As espécies selecionadas são bastante diferentes entre si e ocorrem em diferentes ecossistemas.

3 Material e Métodos

A abordagem proposta neste trabalho para reconhecer as principais pragas da cultura algodoeira por imagens de campo é composta por quatro fases, conforme ilustrado na Figura 3.1. A primeira fase consiste na organização de um conjunto de dados de imagem de pragas primárias e secundárias para culturas de algodão. A segunda fase consiste na integração do banco de imagens de pragas com as redes neuronais clássicas e as redes residuais profundas. A terceira fase constitui-se do processo de treinamento e classificação das redes neuronais. A quarta e última fase contempla o uso dos modelos de redes neuronais convolucionais, no intuito de demonstrar os resultados comparativos de classificação entre os classificadores LBP-SVM, como AlexNet, ResNet-34, ResNet-50 e Resnet-34*.

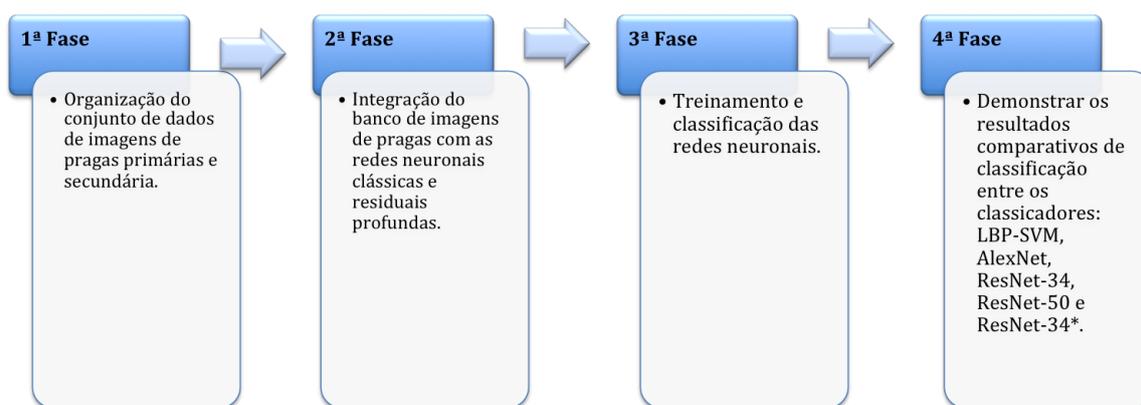


Figura 3.1 – Imagens ilustrativas das quatro fases utilizadas no processo de reconhecimento das principais pragas da cultura algodoeira por imagens de campo.

No processo de treinamento das redes neuronais convolucionais realizou-se o emprego da biblioteca de aprendizagem profunda Fastai (HOWARD, 2018), que é uma biblioteca de código aberto, em que se visa simplificar o processo de treinamento, tornando-o mais rápido e preciso. Isso resultando em uma precisão e velocidade significativamente melhoradas em relação a outras bibliotecas de aprendizado profundo, enquanto exigem drasticamente menos código. Há uso, ainda, do *backend PyTorch*(PASZKE et al., 2017) que é uma biblioteca de tensores otimizada para aprendizagem profunda usando unidade

de processamento gráfico (GPU) e unidade central de processamento (CPU).

3.1 Conjunto de Dados

Ao se obter as imagens, em primeiro momento, procurou-se identificar, na literatura, quais eram as pragas pertencentes ao ecossistema do algodão, posteriormente foi realizada a categorização das principais pragas-alvo em primárias e secundárias; após isso, realizou-se a busca por imagens das pragas categorizadas. A organização do conjunto de dados de imagens de pragas de campo ocorreu pela separação de imagens em classes de pragas primárias e secundárias. Assim, o conjunto de dados imagens é constituído de 15 classes de imagens diferentes de pragas: onze (11) classes de insetos (sendo 3 em fase larval), uma de ácaro (*Tetranychus urticae*) e três fases adultas advindas das fases larvais (*Helicoverpa armigera*, *Heliothis virescens* e *Spodoptera frugiperda*), consideradas as principais pragas do ecossistema de algodão (MONSANTO, 2015). Após esses procedimentos, efetuou-se a separação das imagens por classe de pragas, de forma a obter o mesmo quantitativo de imagens por classe, buscando alcançar a proporcionalidade entre as classes. A posterior extensão do conjunto de dados foi alcançada em virtude da realização das transformações geométricas e radiométricas (GONZALEZ; WOODS, 2000) aplicadas às imagens originais, sendo: rotação de 90° , -90° e 180° graus, zoom aleatório de até 1,5x e alongamento aleatório, rotação aleatória máxima dentro de um intervalo de 10 graus, variação de intensidade de pixel para simular diferentes condições de iluminação, visualizadas nas Figuras 3.2 e 3.3.

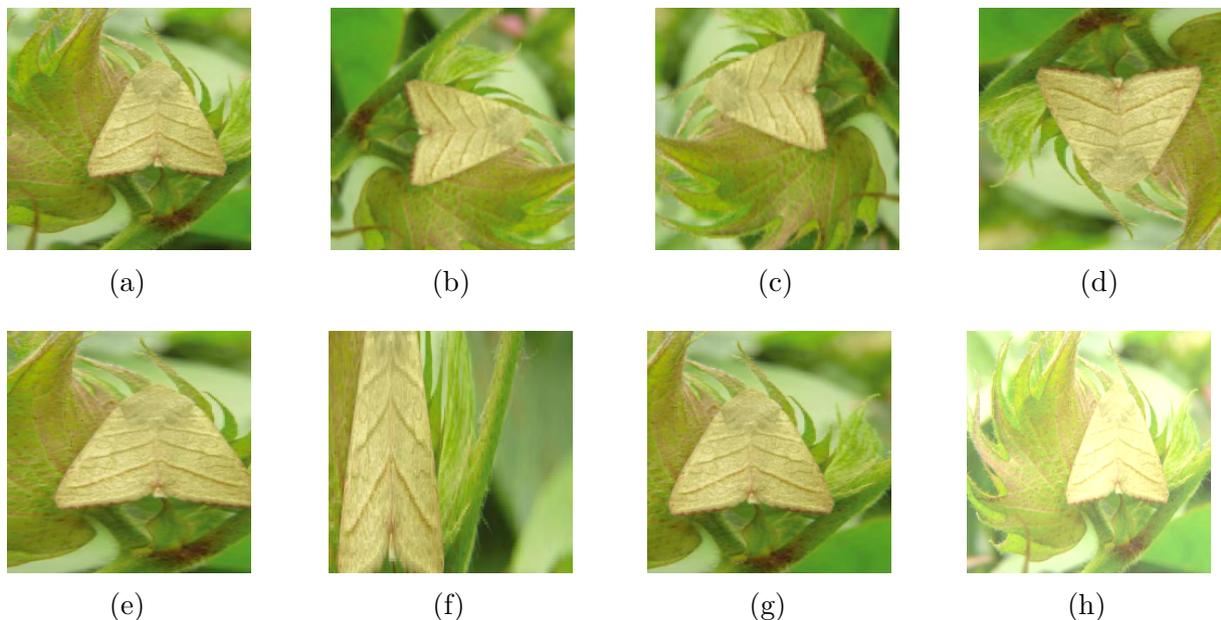


Figura 3.2 – Ilustração de transformações realizadas em imagens do conjunto de dados de pragas primárias. (a) Imagem original; (b) Rotação de 90° ; (c) Rotação de -90° ; (d) Rotação de 180° ; (e) Zoom aleatório de até 1,5x; (f) Alongamento aleatório; (g) Rotação aleatória máxima dentro de um intervalo de 10° graus; (h) Variação de intensidade de pixel para simular diferentes condições de iluminação.

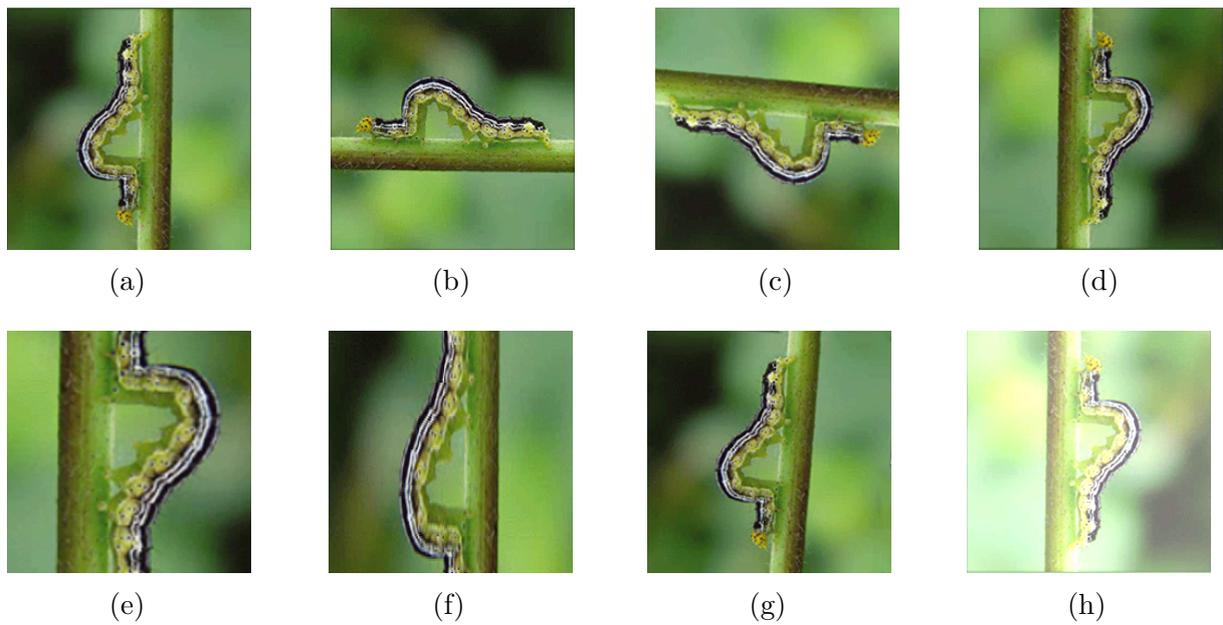


Figura 3.3 – Ilustração de transformações realizadas em imagens do conjunto de dados de pragas secundárias. (a) Imagem original; (b) Rotação de 90° ; (c) Rotação de -90° ; (d) Rotação de 180° ; (e) Zoom aleatório de até 1,5x; (f) Alongamento aleatório; (g) Rotação aleatória máxima dentro de um intervalo de 10° graus; (h) Variação de intensidade de pixel para simular diferentes condições de iluminação.

A maioria das imagens foram adquiridas por pesquisadores da entomologia em diferentes partes do mundo e fornecidas como cortesia para o desenvolvimento do trabalho. Em especial agradecemos à Profa. Dra. Cristina Schetino Bastos (FAV, UnB), e sua equipe, pelo auxílio na coleta em campo de parte das imagens feita na Fazenda Água Limpa da UnB.

A proporção final do conjunto de imagens de treinamento e validação obedeceu à proporção de 80% para treinamento e 20% para teste. Todas as imagens foram redimensionadas para o tamanho (224 x 224) pixel, no formato PNG 3 cores (RGB). As Tabelas 1 e 2 demonstram claramente o quantitativo e a proporção de imagens originais, bem como para o conjunto de imagens ampliadas também. Já a Figura 3.4 ilustra os tipos de espécie de pragas presentes no conjunto de imagens de pragas primárias, ao mesmo tempo em que a Figura 3.5 ilustra os tipos de espécies presentes no conjunto de imagens de pragas secundárias.

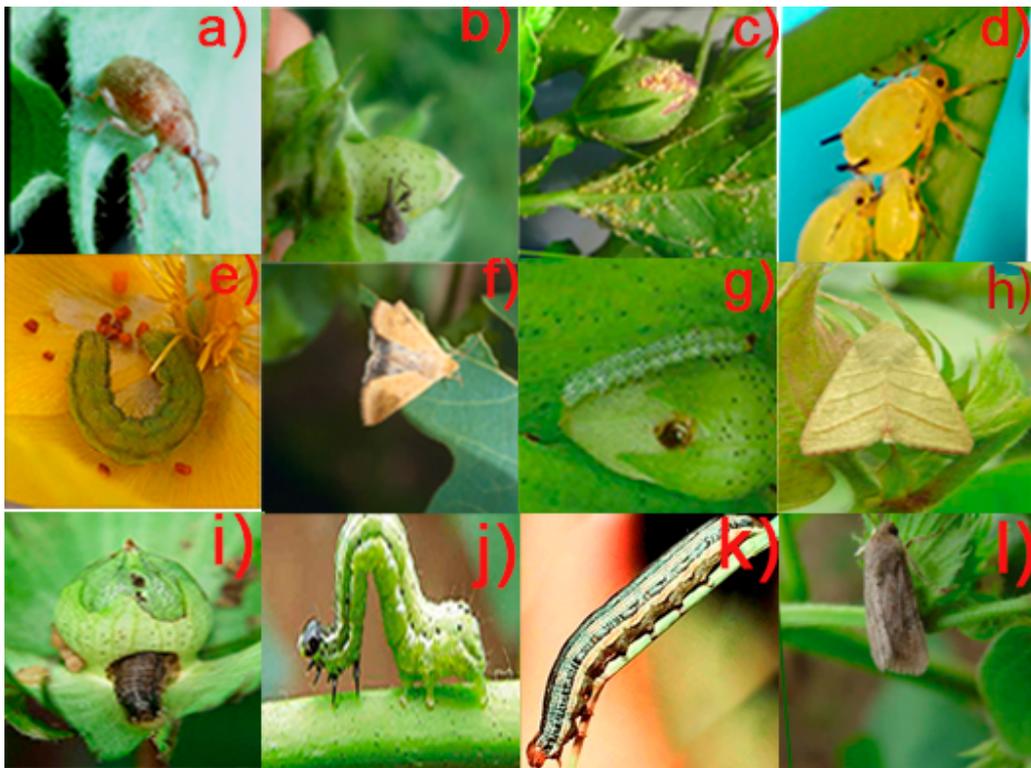


Figura 3.4 – Imagens de pragas de campo para classe primárias: a, b) *Anthonomus grandis*, c, d) *Aphis gossypii*, e) *Helicoverpa armigera* (larva), f) *Helicoverpa armigera* (adulto), g) *Heliothis virescens* (larva), h) *Heliothis virescens* (adulto), i, j) *Pseudoplusia includens*, k) *Spodoptera frugiperda* (larva), l) *Spodoptera frugiperda* (adulto).

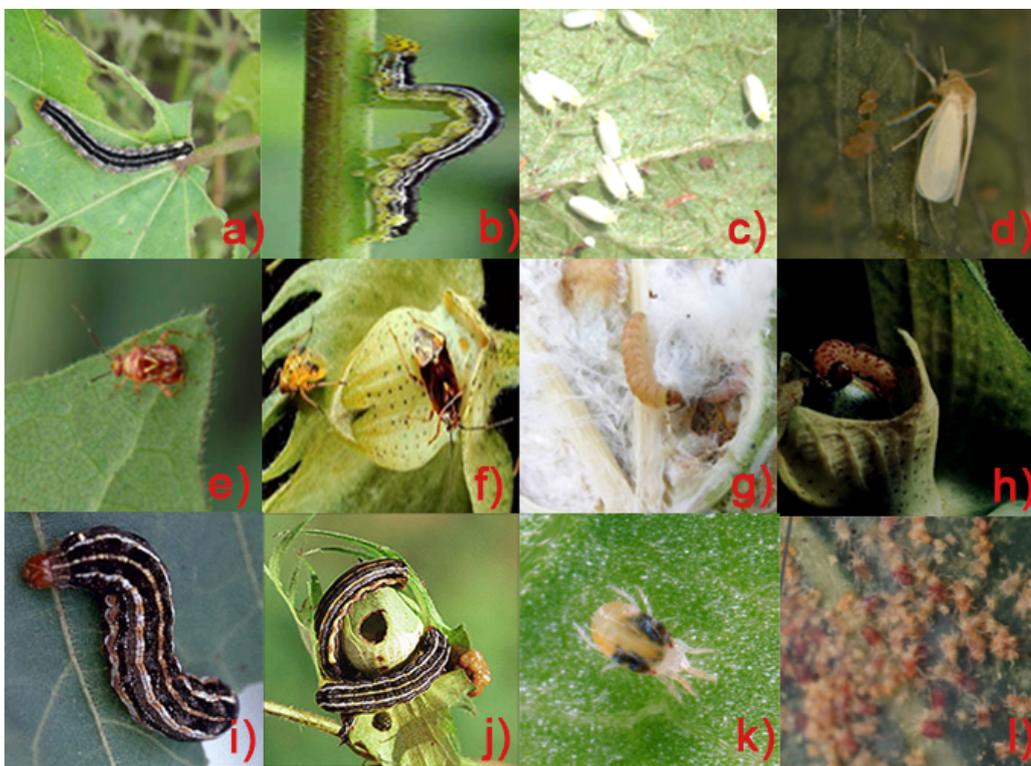


Figura 3.5 – Imagens de pragas de campo para classe secundários: a, b) *Alabama argillacea*, c, d) *Bemisia tabaci*, e, f) *Horcias nobilellus*, g, h) *Pectinophora gossypiella*, i, j) *Spodoptera eridania*, k, l) *Tetranychus urticae*.

Nome científico	Original Treinamento	Original Validação
<i>Anthonomus grandis</i>	80	20
<i>Aphis gossypii</i>	80	20
<i>Helicoverpa armigera</i> (larva)	80	20
<i>Helicoverpa armigera</i> (adult)	80	20
<i>Heliothis virescens</i> (larva)	80	20
<i>Heliothis virescens</i> (adulta)	80	20
<i>Pseudoplusia includens</i>	80	20
<i>Spodoptera frugiperda</i> (larva)	80	20
<i>Spodoptera frugiperda</i> (adulta)	80	20
<i>Alabama argillacea</i>	80	20
<i>Bemisia tabaci</i>	80	20
<i>Horcias nobilellus</i>	80	20
<i>Pectinophora gossypiella</i>	80	20
<i>Spodoptera eridania</i>	80	20
<i>Tetranychus urticae</i>	80	20
Não Pragas	80	20
Total	1280	320

Tabela 1 – Número de imagens originais por classe de inseto do banco de imagens.

Nome científico	Originais	Ampliadas
<i>Anthonomus grandis</i>	100	620
<i>Aphis gossypii</i>	100	620
<i>Helicoverpa armigera</i> (larva)	100	620
<i>Helicoverpa armigera</i> (adulta)	100	620
<i>Heliothis virescens</i> (larva)	100	620
<i>Heliothis virescens</i> (adulta)	100	620
<i>Pseudoplusia includens</i>	100	620
<i>Spodoptera frugiperda</i> (larva)	100	620
<i>Spodoptera frugiperda</i> (adulta)	100	620
<i>Alabama argillacea</i>	100	620
<i>Bemisia tabaci</i>	100	620
<i>Horcias nobilellus</i>	100	620
<i>Pectinophora gossypiella</i>	100	620
<i>Spodoptera eridania</i>	100	620
<i>Tetranychus urticae</i>	100	620
Não pragas	100	620
Total	1600	9920

Tabela 2 – Quantitativo de imagem originais e ampliadas para cada classe do conjunto de dados.

3.2 Técnicas de Reconhecimento

A aprendizagem de máquina supervisionada é um procedimento que compreende aprender um conjunto de regras, com base em exemplos e instâncias de um conjunto de treinamento. Da mesma forma, pode ser estabelecido como a criação de um classificador

que pode ser difundido para novas instâncias, ausentes no conjunto de treinamento. O classificador é um paradigma que, depois de ser empregado o treinamento, pode determinar classes de instâncias de testes, as quais são desconhecidas, aplicando a informação dos seus atributos (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007). As máquinas de vetores de suporte são exemplos de classificadores, os quais foram utilizados neste trabalho para fins de comparação com as redes neuronais convolucionais. Utilizou-se um modelo com recursos padrões binários locais (LBP) seguido por uma máquina de vetores de suporte (SVM) (EBRAHIMI et al., 2017), em que padrões binários locais (LBP) são utilizados como recursos para descrição de textura de imagem, o LBP vai medir a textura invariante de uma imagem em escala de cinza com a utilização de vizinhanças locais, seu operador básico substitui os valores de pixel por rótulos, binarizando vizinhanças em torno de cada pixel, tendo o pixel central como um limite. Os rótulos de pixel são convertidos em números decimais. Esse processo é realizado para todos os *pixels* da imagem, estando cada pixel definido como o ponto central e tendo seu rótulo a partir do cálculo em relação aos seus vizinhos, de acordo com a Figura 3.6. Nesta, ao se deslocar a imagem no sentido anti-horário, a contar da célula central esquerda, conquista-se o valor binário 0011100001110101, equivalente ao valor decimal 28905. Logo após efetuar esse cálculo para todos os *pixels* presentes na imagem, o histograma dos rótulos dos *pixels* é, então, empregado como um extrator de textura.

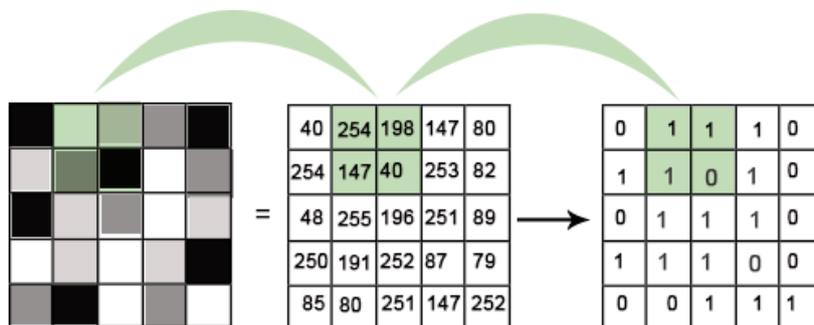


Figura 3.6 – Exemplo de extração de LBP. A matriz em escala de cinza representa a amostra de uma imagem, em seguida a matriz central da figura descreve os valores números para escala de cinza (0 até 255). Por fim a matriz binarizada à direita da matriz numérica apresenta a transformação aplicada, em que os valores acima de 127 equivale a 1 e os abaixo são equivalentes a 0.

O propósito do SVM é prover uma amostra com base nos dados do conjunto de treinamento, que prevê os valores de destino dos dados de teste, dados apenas dos atributos extraídos do conjunto de dados de teste. As máquinas de vetores de suporte podem ser generalizadas para classificadores não-lineares. Para tal, são empregadas funções *Kernel*, que abrangem, por exemplo, não-linearidades gaussianas e polinomiais (PLATT, 1998). Apesar de o algoritmo fornecer uma solução para problemas binários, essa solução pode ser generalizada para problemas com múltiplas classes. Isso pode ser alcançado por meio de duas estratégias: realizando o teste de uma classe contra todas as outras ou uma abordagem com vários testes entre duas classes (EBRAHIMI et al., 2017). O LBP é

aplicado em *patches* multibloco na imagem, em diferentes escalas. Depois de rotular as partes da imagem, o histograma de recursos é gerado dos rótulos da região local (PLATT, 1998).

Utilizou-se o SVM no processo de classificação do conjunto de dados de imagens de pragas, o qual funciona como um classificador que utiliza a abordagem de aprendizagem supervisionada (WU; LU; WANG, 2010). Ele analisa conjuntos de vetores de recursos em um espaço dimensional qualquer, usando os vetores de suporte para construir um hiperplano para separar classes diferentes, maximizando a margem entre elas definida pelo hiperplano concedido. São modelos computacionais com múltiplas camadas de processamento, capazes de aprender com os dados, cujas estruturas intrínsecas classificam com precisão os padrões em situações desafiadoras, como é o ambiente de terras agrícolas (GASSOUMI; PRASAD; ELLINGTON, 2000).

Com o propósito de comparação entre as redes neuronais convolucionais e a abordagem de LBP-SVM (EBRAHIMI et al., 2017), foi realizado o uso de um LBP-SVM com uma vizinhança local de 24 *pixels* e raio de 8, com probabilidade de escolha $p = 42\%$. Todas as imagens no treinamento SVM foram convertidas em escala de cinza para extrair histogramas usando a entrada adicional no modelo. Todos os modelos CNN tiveram um tamanho de lotes em 32 *batch*. Para os modelos residuais, a taxa de aprendizado foi escolhida com base em uma abordagem de varredura que testou valores de 10^{-22} à 10^1 antes do início do treinamento com diferentes iterações, retornando os valores de perda e a respectiva precisão de cada taxa de aprendizagem de teste. Como o menor valor de erro foi em torno de 0,1, foi selecionado o valor 0,01 (uma magnitude menor) para iniciar a sequência de treinamento.

3.2.1 Redes Neuronais Convolucionais (RNCs)

As Redes Neuronais Convolucionais usadas aqui pertencem a uma classe de RNCs tipo *feed-forward* que foram aplicadas com sucesso à análise de imagens em diversos contextos, em que usam a convolução em pelo menos uma de suas camadas. Essas estruturas de rede são variantes, biologicamente inspiradas de perceptrons multicamadas que emulam o córtex visual, o mais poderoso sistema de processamento visual existente.

A Convolução consiste em uma operação matemática entre duas funções f e g , constituindo uma terceira função, que pode ser entendida com uma função modificada de f . No processo de manipulação de imagens, em que a imagem é estabelecida como uma função bidimensional, a convolução é útil na detecção de bordas, suavização de imagens, extração de características, dentre outras aplicações (PARKER, 2010). Dada as funções f e g , para uma variável discreta x , em que $*$ caracteriza o operador de convolução. Para as funções f e g , quando x está definido no conjunto Z de inteiros, a equação da convolução

discreta é determinada por:

$$f[x] * g[x] = \sum_{n=-\infty}^{\infty} f[n].g[x - n] \quad (3.1)$$

O entendimento de como ocorre a convolução em uma imagem é interpretado pelo somatório de cada elemento da imagem, junto com seus vizinhos locais e pelos elementos da matriz, que correspondem ao filtro de convolução. A ilustração de cálculo se faz mediante à Figura 3.7. É utilizada, neste exemplo, uma aplicação de filtro de convolução em que a imagem original é reduzida em tamanho simétrico às dimensões do filtro utilizado.

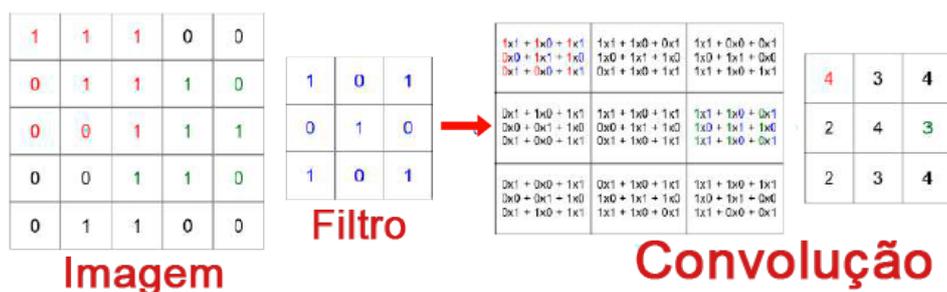


Figura 3.7 – Ilustração de um modelo de aplicação da convolução na imagem. À esquerda, uma imagem hipoteticamente representada por um único canal com dimensões 5x5 que recebe a aplicação de um filtro 3x3. À direita, uma matriz ilustrando o somatório que fornece o resultado da convolução.

As RNCs comprovaram ser capazes e competentes em diversas tarefas de reconhecimento de imagens e vídeos, sistemas de recomendação, processamento de linguagem natural e classificação de imagens, no entanto há a necessidade de uma ampla quantidade de amostras rotuladas para a sua aprendizagem. As redes neurais convolucionais tornaram-se um novo padrão em visão computacional, em virtude da sua facilidade em treinar grandes quantidades de amostras rotuladas que representam as diferentes classes, bem como pela sua eficácia em extrair características importantes por meio de *kernels* (aprendizagem de transformações), necessitando de mínimos ajustes em seus parâmetros em relação às redes totalmente conectadas com igual quantidade de camadas ocultas (LECUN et al., 1998). A sua arquitetura foi projetada para realizar o processamento de dados armazenados no formato de múltiplas matrizes em uma dimensão para sinais e sequências, duas ou três dimensões para vídeos e imagens volumétricas. O êxito das redes convolucionais no reconhecimento de objetos é uma das principais razões pelas quais o mundo testemunhou a eficácia da aprendizagem profunda. Inúmeras arquiteturas foram propostas nos últimos anos como objetivo de melhoria das redes neurais artificiais do tipo *feed-forwards* (LECUN et al., 1998), embora as versões de RNC melhoradas compartilhem de conceitos fundamentais, que são RNCs constituídas por sequências de camadas, em que cada uma das camadas possui uma função específica na propagação do sinal de entrada. As camadas convolucionais são encarregadas por extrair características dos dados de entradas. As camadas de agrupamento (*pooling*) são incumbidas de moderar

a dimensionalidade do dado resultante após as camadas convolucionais e auxiliam tornar a representação invariante a breves translações na entrada. As camadas totalmente conectadas são responsáveis pela disseminação do sinal, por meio da multiplicação ponto a ponto e do uso de uma função de ativação. A função de regularização de decaimento de peso por época (Adam) são equivalentes para descida de gradiente estocástica padrão (quando é reescalada pela taxa de aprendizado), em que sua função visa desacoplar o peso das etapas de otimização para a função de perda (KINGMA; BA, 2014). A duração do ciclo completo (para cima e para baixo) é ajustada para ser ligeiramente menor que o número total de épocas de treinamento, de modo que as épocas restantes após o ciclo sejam treinadas com a diminuição da taxa de aprendizado para ajudar o modelo a se estabilizar. A saída esperada em um RNC é a possibilidade de a imagem de entrada ser a uma das classes para qual a rede foi treinada.

A Figura 3.8 mostra a arquitetura de uma RNC típica e suas três principais camadas: convolucionais, de *pooling* e totalmente conectadas.

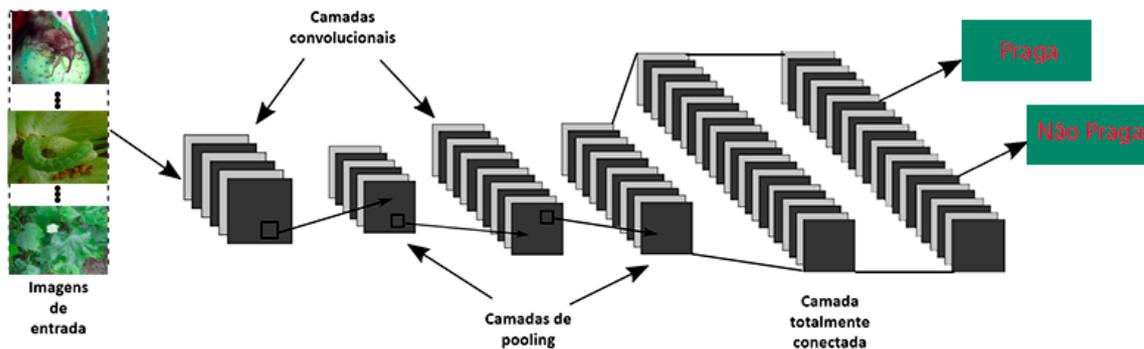


Figura 3.8 – Ilustração da arquitetura de uma rede neural convolucional padrão que classifica imagens de entradas com imagens de pragas do algodão ou não pragas e suas três principais camadas: convolucionais, de *pooling* e totalmente conectadas.

3.2.1.1 Camada Convolutiva

A camada de convolução constitui-se de mapas de características ou atributos conectados a cada elemento da camada anterior por meio de um grupo de parâmetros compartilhados entre todas os elementos e possui ReLus (*Rectified Linear Units*), neurônios com função de ativação definida como a não-linearidade na forma descrita na equação 3.2. As camadas convolucionais constituem-se de um conjunto de filtros, que ganham como entrada um arranjo 3D, denominado volume. Cada filtro possui dimensão reduzida, contudo ele se estende por toda a profundidade do volume de entrada. Por exemplo, se a imagem for colorida, ela possui 3 canais e o filtro da primeira camada convolutiva terá tamanho $5 \times 5 \times 3$ (5 *pixels* de altura e largura, e profundidade igual a 3). De forma automática, no decurso do treinamento da rede, esses filtros são ajustados com o propósito de que sejam ativados em presença de características significativas do dado de entrada,

como orientação de bordas ou manchas de cores (RAWAT; WANG, 2017). A importância é ponderada de tal forma que os resultados sejam otimizados em função de um conjunto de amostras previamente classificadas.

Cada um desses filtros dá origem a uma estrutura localmente conectada, que perpassa toda a extensão do volume de entrada. O somatório do produto ponto a ponto entre os valores de um filtro e cada posição do volume de entrada é uma operação comumente conhecida como convolução, que é demonstrada na Figura 3.9. Os valores oriundos após a operação de convolução passam por uma função de ativação, e a mais comum é a função ReLU (HOWARD et al., 2017). A função ReLU pode ser calculada pela Equação 3.2.

$$f(x) = \max(0, x) \quad (3.2)$$

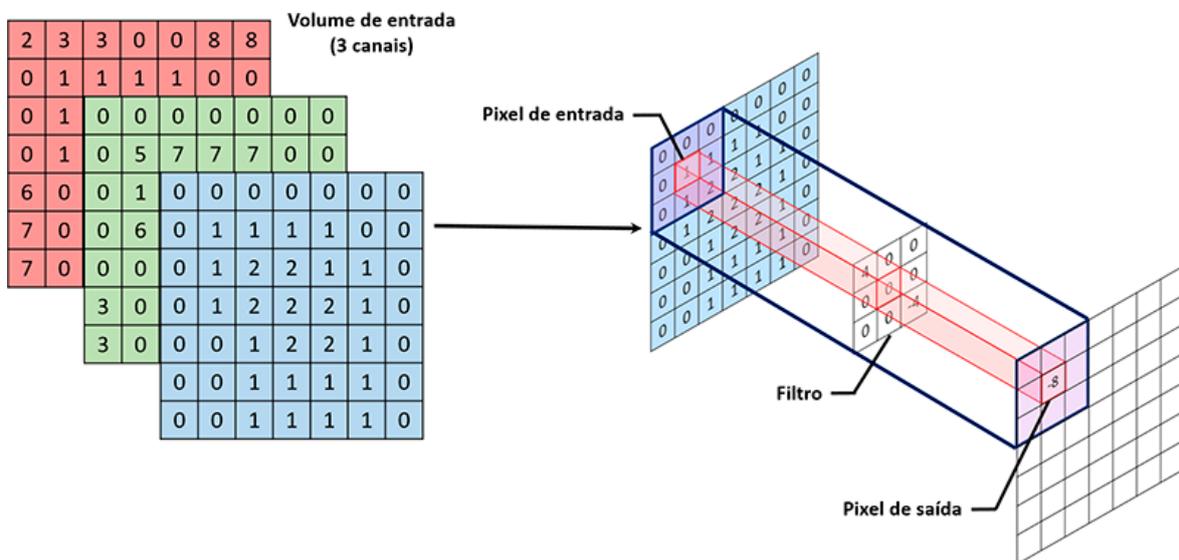


Figura 3.9 – Ilustração da convolução de uma imagem colorida(RGB) entre um filtro 3x3.

São três os parâmetros que influenciam o tamanho do volume resultante da camada convolucional: profundidade (*depth*), passo (*stride*) e zero *padding* (KARN, 2016). A profundidade do volume resultante é igual ao número de filtros utilizados, cada um dos filtros será responsável por extrair características diferentes no volume de entrada. Portanto, quanto maior o número de filtros, maior o número de características extraídas, porém a complexidade computacional, relativa ao tempo e ao uso de memória, também será maior.

3.2.1.2 Camadas de seleção e agrupamento (*pooling*)

Depois de uma camada convolucional, normalmente existe uma camada de agrupamento (*pooling*). O propósito dessa camada é reduzir gradativamente a proporção espacial do volume de entrada, assim a redução diminui o custo computacional da rede, evitando sobreajuste (*overfitting*) (HOWARD et al., 2017). No procedimento de agrupamento, os

valores tocantes a uma determinada região do mapa de atributos, gerados pelas camadas convolucionais, são substituídos por alguma métrica dessa região. A forma mais comum de agrupamento consiste em substituir os valores de uma região pelo valor máximo (GOODFELLOW; BENGIO; COURVILLE, 2016), como mostra a Figura 3.10. A operação *max pooling* é útil para eliminar valores desprezíveis, pois reduzindo a dimensão da representação dos dados e acelera a computação necessária para as próximas camadas, além de criar uma invariância a pequenas mudanças e distorções locais.

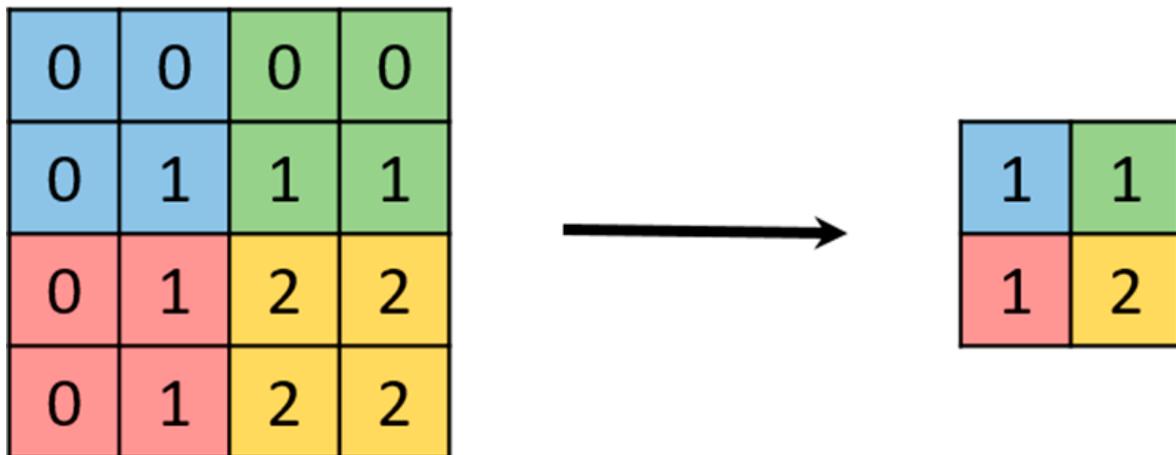


Figura 3.10 – Aplicação de *max pooling* em uma imagem 4x4, utilizando um filtro 2x2. Além de reduzir o tamanho da imagem, consequentemente reduzindo o processamento para as próximas camadas, essa técnica também auxilia no tratamento de invariâncias locais.

3.2.1.3 Camada Totalmente Conectada

A finalidade das camadas totalmente conectadas é utilizar as saídas das camadas convolucionais e de *pooling*, que representam as características extraídas da imagem de entrada para classificá-la em uma classe pré-determinada. Essas camadas são geradas por unidades de processamento conhecidas como neurônio, e o termo “totalmente conectado” significa que todos os neurônios da camada anterior estão conectados a todos os neurônios da camada seguinte. Naturalmente no contexto de classificação de imagem a última camada da rede utiliza softmax como função de ativação. Essa função recebe um vetor de valores quando entra e produz a distribuição probabilística da imagem de entrada pertencer a cada uma das classes às quais a rede foi treinada para reconhecer. Vale destacar que a soma de todas as probabilidades é igual a 1. Um técnica conhecida como descarte(*dropout*) (GOODFELLOW; BENGIO; COURVILLE, 2016) também é bastante utilizada entre as camadas totalmente conectadas, para reduzir o tempo de treinamento e evitar sobreajuste (*overfitting*). Essa técnica consiste em remover aleatoriamente, a cada interação de treinamento, uma determinada porcentagem dos neurônios de uma camada, readicionando-os na interação seguinte. Essa técnica também confere à rede a habilidade de

extrair características mais robustas, uma vez que um neurônio não pode depender da presença específica de outros neurônios.

3.2.2 AlexNet

AlexNet, em homenagem a Alex Krizhevsky (LECUN; BENGIO; HINTON, 2015), alcança bons resultados desde 2012, em tarefas de classificação de imagens e se tornou um modelo padrão de RNC. A arquitetura do AlexNet possui 8 camadas, nas quais 5 delas são núcleos de convolução e as outras três são camadas totalmente conectadas, como se pode verificar na Figura 3.11. A arquitetura padrão da AlexNet faz o uso do ReLU (Unidade Linear Retificada) para a parte não linear, em vez de uma função *Sigmoid*, que era o padrão anterior para as redes neuronais tradicionais. Sua camada final densa (ou totalmente conectada) alimenta uma função *softmax*. Quanto maior o número de camadas empilhadas, maior precisão será obtida (HE et al., 2016), mas também tornou as redes mais profundas mais suscetíveis à saturação precoce (quando a rede pára de melhorar) e, mais rapidamente, à degradação (quando não só melhora, mas também pode perder desempenho por sobreajuste (*overfitting*)) (HE et al., 2016). Uma solução proposta é mudar o primeiro modelo sequencial adotado para o mapeamento das camadas, de forma que elas não apenas se conectem a camadas contíguas, mas também conectem diretamente à enésima camada. Isso possibilitou uma combinação de atalhos entre camadas e ajudou a manter a estabilidade da rede (HE et al., 2016).

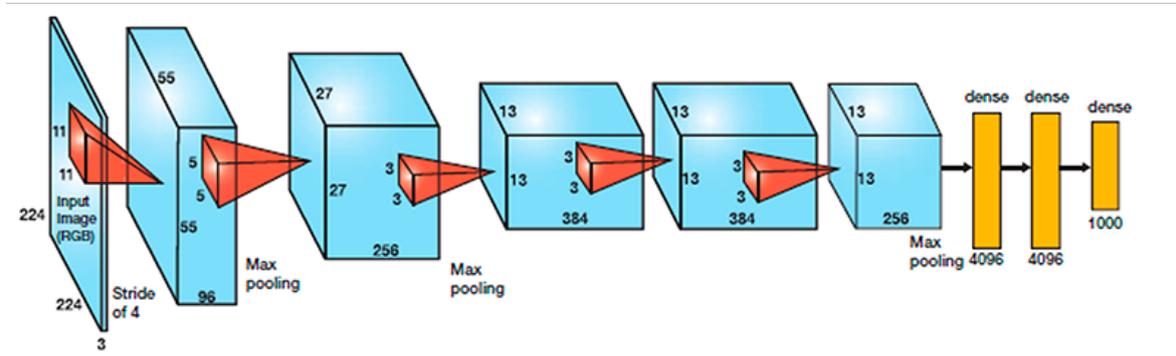


Figura 3.11 – Modelo de arquitetura da AlexNet padrão.

3.2.3 ResNet-34

A rede ResNet (HE et al., 2016) foi proposta por pesquisadores da *Microsoft* e venceu em primeiro lugar o ILSVRC 2015 entre as cinco melhores, com erro de 3.6% no conjunto de testes do ImageNet. As redes profundas extraem recursos e classificadores de nível baixo, médio e alto em um modo multicamada de ponta a ponta, e o número de camadas empilhadas pode enriquecer os “níveis” de recursos. A ResNet era composta por 152 camadas e formada por blocos residuais. A ideia por trás dos blocos residuais é que

uma entrada x passa por uma série de operações de convolução, ReLU e convolução. A formulação de $F(x) + x$ pode ser realizada por redes neurais *feedforward*, com conexões de atalho, que são aquelas que pulam um ou mais camadas. O resultado da operação $F(x)$ é adicionado à entrada original x , como mostra a Equação 3.3 ilustrado na Figura 3.12.

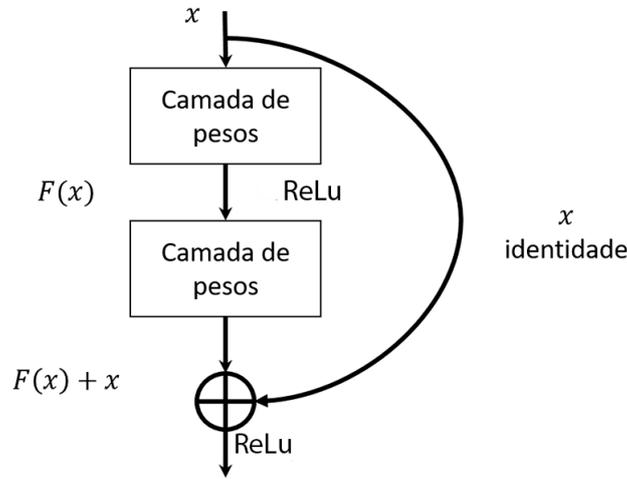


Figura 3.12 – Arquitetura de um bloco residual.

$$H(x) = F(x) + x \quad (3.3)$$

Nas RNCs tradicionais, o resultado de processamento $H(x)$ é igual ao $F(x)$. Com isso, o espaço de saída é completamente alterado em relação ao espaço de entrada x . Com relação à ResNet, a função $F(x)$ funciona somente como um termo de regularização. Portanto, o espaço de saída é somente uma alteração do espaço de entrada.

Com base na arquitetura padrão da ResNet, inserida uma conexão de atalho que transforma a rede em sua versão residual correspondente, como se vê na Figura 3.13. Os atalhos de identidade $F(xW + x)$ podem ser usados diretamente quando a entrada e a saída são das mesmas dimensões. Quando as dimensões aumentam, há duas opções: O atalho executa o mapeamento de identidade, com entradas zero extras preenchidas para aumentar as dimensões (essa opção não introduz nenhum parâmetro adicional); Ou o atalho de projeção em $F(xW + x)$ é usado para corresponder dimensões (feitas por 1Ö1 convoluções).

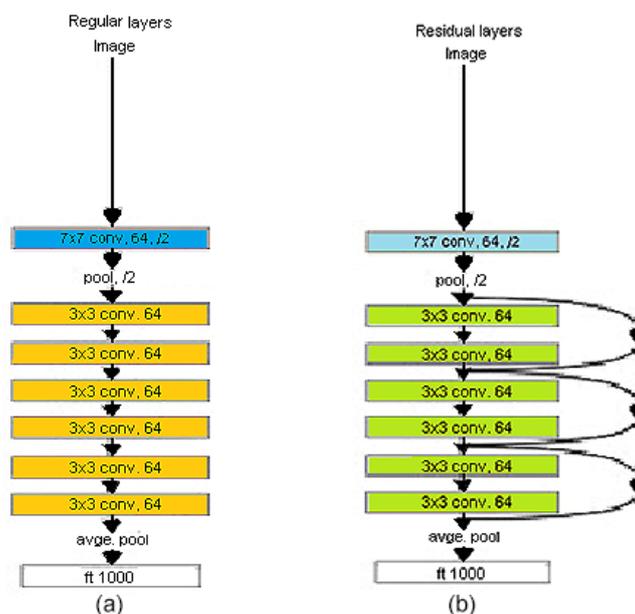


Figura 3.13 – Redes regulares (a) e residuais (b) profundas típicas mostrando o fluxo de informação entre as camadas.

A ResNet-34 é uma rede residual profunda. O número “34” refere-se à quantidade de camadas que ela possui.

3.2.4 Resnet-34*

Uma das contribuições deste trabalho é um modelo residual profundo modificado (ResNet-34*). A última camada linear do modelo original é substituída por 7 camadas adicionais, como é mostrado na Figura 3.14. A hipótese dessa modificação proposta é inicialmente melhorar a aprendizagem na parte final de treinamento (permitindo que a rede aumente sua capacidade discriminatória) e, em seguida, ocorrem normalizações (*Batch normalization*) e duas camadas de descarte (*dropout*), 70% e 50%, com o objetivo de acelerar o treinamento e reduzir as possibilidades de *overfitting* por meio da redução de grande oscilações da queda de gradiente nas últimas épocas de treinamento (SANTURKAR et al., 2018). Além disso, a operação de descarte nas camadas adicionais do modelo impede que a rede fortaleça caminhos específicos de determinados parâmetros ao longo das camadas de convolução, fazendo com que a rede possa realizar a predição independentemente da configuração dentro do grafo da rede. A normalização em lote (*Batch normalization*) ajuda a readequar os sinais provenientes das ativações para um intervalo de ativações obtidos no lote atual, de forma que não haja sinais com maior valor sendo favorecidos pelo grande intervalo entre sinais com menor valor. Assim, a normalização fornece ativações para blocos residuais por meio do cálculo da média e do desvio padrão para cada resposta do filtro de convolução (SANTURKAR et al., 2018). A operação é feita em cada mini-lote em cada iteração para normalizar a ativação da camada atual antes de avançar para a camada seguintes. As modificações propostas (ResNet-34*) trabalham lado a lado, permitindo

melhor convergência do modelo modificado demonstrado na Figura 3.14 em relação ao modelo original apresentado na Figura 3.13, sem diminuir as taxas de precisão. A proporção de descarte foi estabelecido por meio de testes empíricos. De fato, melhorou a precisão geral, como é mostrado nos experimentos.

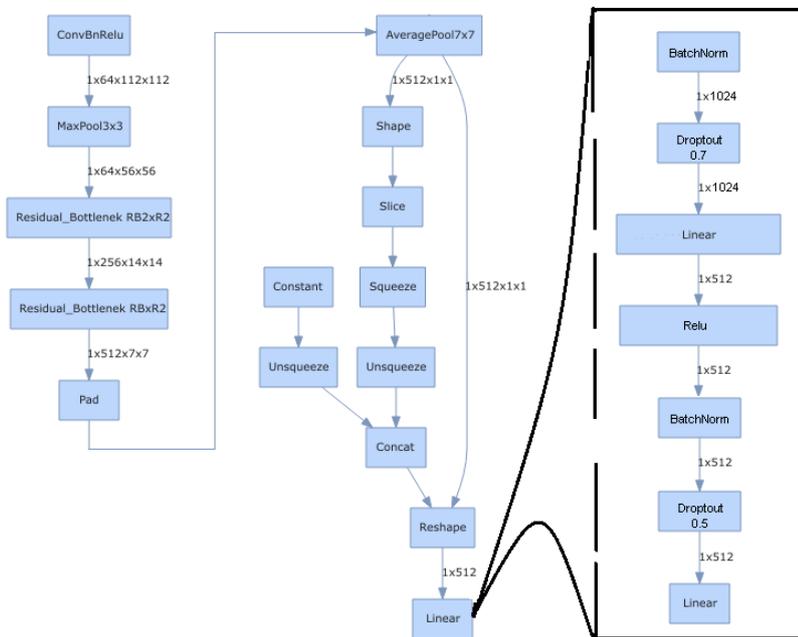


Figura 3.14 – ResNet-34* modificada: a última camada linear do modelo original é substituída por 7 camadas adicionais lineares originais.

3.2.5 ResNet-50

A ResNet-50 é uma rede residual profunda. O número “50” refere-se à quantidade de camadas que ela possui (HE et al., 2016). É uma subclasse de redes neurais convolucionais, com a ResNet, popularmente usada para classificação de imagens. A principal inovação da ResNet-50 é a conexão *skip* (salto). As redes residuais profundas sem ajustes, geralmente, sofrem de gradientes de fuga, ou seja: como o modelo retropropaga, o gradiente fica bem menor. Gradientes menores podem tornar a aprendizagem intratável. A conexão de salto, conforme mostrado na figura 3.12, é rotulada como “identidade”. Ela permite que a rede aprenda a função de identidade, o que permite que ela passe pela entrada através do bloco, sem passar pelas outras camadas de peso. Na Figura 3.15, observa-se que cada bloco colorido de camadas representa uma série de convoluções da mesma dimensão. O mapeamento de recursos é periodicamente reduzido por convolução guiada acompanhada por um aumento na profundidade do canal para preservar a complexidade de tempo por camada. Linhas pontilhadas denotam conexões residuais nas quais projetam a entrada por meio de uma convolução de 1x1 para corresponder às dimensões do novo bloco.

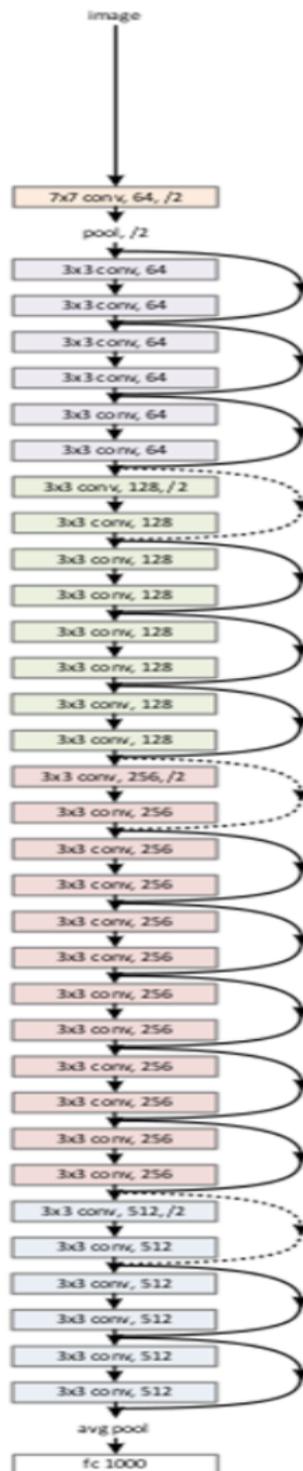


Figura 3.15 – Arquitetura de uma rede residual (ResNet-50)

3.3 Processo de Treinamento

Durante o processo de treinamento das RNCs, o número de imagens foi igual ao número fornecido pelo conjunto de imagens de treinamento, que é de 560 imagens, colocadas em mini-lotes de 32 *batch*. Todas as redes treinadas foram configuradas com a função de regularização de decaimento de perdas (Adam), que é semelhante ao gradiente estocástico de descida após ser redimensionada pela taxa de aprendizado. A função Adam baseia-se no momento e possui duas variáveis para ele (α and β), obtidas por médias móveis. Seus valores variam de 0,9 a 0,999 como sugerido por Kingma (KINGMA; BA, 2014). Vale salientar que o processo de treinamento do modelo SVM com LBP utiliza configurações diferentes, devido às configurantes inerentes ao modelo como o fator de regularização (C) igual a $c = 100$, raio de binarização do LBP (R), $r = 8$ e número de vizinho no raio de binarização (V), $v = 24$ com probabilidade de escolha (P) $p = 42\%$, em que esses valores foram obtidos empiricamente. A ordem de treinamento se deu, em primeiro lugar, para as pragas primárias, em seguida, para todas as pragas. A taxa de aprendizagem foi escolhida com base em uma abordagem de varredura, que testou valores de 10^{-22} a 10^1 antes do início do treinamento com diferentes iterações, retornando os valores de perda e a respectiva precisão de cada taxa de aprendizagem de teste, o processo de taxa de varredura é demonstrado na Figura 3.16 e no Algoritmo 2. O Algoritmo 2 testa cada valor e mantém o menor valor, com este menor valor de erro retornado, verifica-se se há uma curva de descida de gradiente antes do menor valor como encontrado na Figura 3.16. Para aproveitar a curva de descida de gradiente, é selecionado um valor de uma magnitude menor que o menor erro, que deve pertencer a descida de gradiente da curva (HOWARD, 2018) como mostrado na Figura 3.16a). Também verifica-se se a taxa de aprendizado escolhida satisfaz o conjunto de validação. A Figura 3.16b) mostra que o conjunto de validação não está com ajuste excessivo quando comparado com a Figura 3.16c), onde o erro de treinamento é mostrado com uma certa simetria. Além disso, a Figura 3.16 representa os valores potenciais de precisão para o conjunto de validação, onde o ponto mais alto é a precisão do menor erro de validação. No entanto, para manter as melhorias na taxa de aprendizado, deve-se escolher um valor menor de uma magnitude na curva de erro de treinamento para evitar a saturação da rede. Como o menor valor de erro foi em torno de 0,1, foi selecionado o valor 0,01 (uma magnitude menor) para iniciar a sequência de treinamento. É empregada a técnica de validação cruzada, em que a biblioteca Fastai realiza o teste com imagens virtuais aleatórias, com oito *minibatches*, em que essas imagens são variações da validação (*augmentation* gerados na hora). O Algoritmo 1 detalha como é o processo de treinamento das RNCs.

Algoritmo 1 Processo de treinamento das RNCs

Data: img_i tal que $i = 0, 1, 2, \dots, X$ com $X=560$

begin

carregarFastai, matplotlib, seaborn, numpy, pandas;

bancoImagens \leftarrow *caminhoDiretorio*;

tamanhoImagem \leftarrow *t*, *batch* \leftarrow *a*, *epoca* \leftarrow *b*;

otimizador \leftarrow *Adam*(α, β);

arquitetura \leftarrow

escolher(*SVM*, *AlexNet*, *ResNet - 34*, *ResNet - 34**, *ResNet - 50*) **if**

arquitetura == *SVM* **then**

C \leftarrow *c*, *R* \leftarrow *r*;

V \leftarrow *v*, *P* \leftarrow *p*;

Rede \leftarrow

parametros(*bancoImagens*, *arquitetura*, *tamanhoImagem*, *C*, *R*, *P*);

end

else

rede \leftarrow *parametros*(*bancoImagens*, *arquitetura*, *tamanhoImagem*,

pesosImageNet, *Otimizador*);

end

estatusTaxa, *taxaInicial* \leftarrow *Algoritmo 2*;

Function *ampliarValidacao*(*decisao*) *validacao* \leftarrow

validacao + *rotacao*(*Validacao*, 5%) + *Zoom*(*Validacao*, 10%) + *Espellhar*(10%)

for $k \in$ *Passos* **do**

if *estatusTaxa* == *Verdadeiro* **then**

epoca \leftarrow *epoca* - 1;

parcial \leftarrow *treinar*(*rede*(*taxaInicial*, *epocas*, *batch*, *X*, *ampVal*));

end

else

taxaInicial \leftarrow *Algoritmo 2*;

if *estatusTaxa* \leftarrow *falso* **then**

ampVal \leftarrow *ampliarValidacao*(*verdadeiro*);

break;

end

end

taxaInicial \leftarrow *Algoritmo 2*;

metricasValidacao \leftarrow *validacao*();

erros \leftarrow *concatenar*(*parcial*, *metricasValidacao*);

end

validacaoCruzada \leftarrow *valCruzada*(*DefaultFastai* = 8);

resultados \leftarrow *concatenar*(*validacaoCruzada*, *fscore*());

end

Algoritmo 2 Algoritmo de Abordagem Varredura

```
begin
  Function Varredura(taxaInicial, taxaFinal)
  for  $I \in 1000$  do
    |  $taxa \leftarrow Min(Treinar(taxaInicial, taxaFinal));$ 
  end
  if  $estatusTaxa = Treinavel(taxaInicial)$  then
    |  $return(taxaInicial, Verdadeiro)$ 
  end
  else
    |  $return(taxaInicial, Falso)$ 
  end
end;
end
```

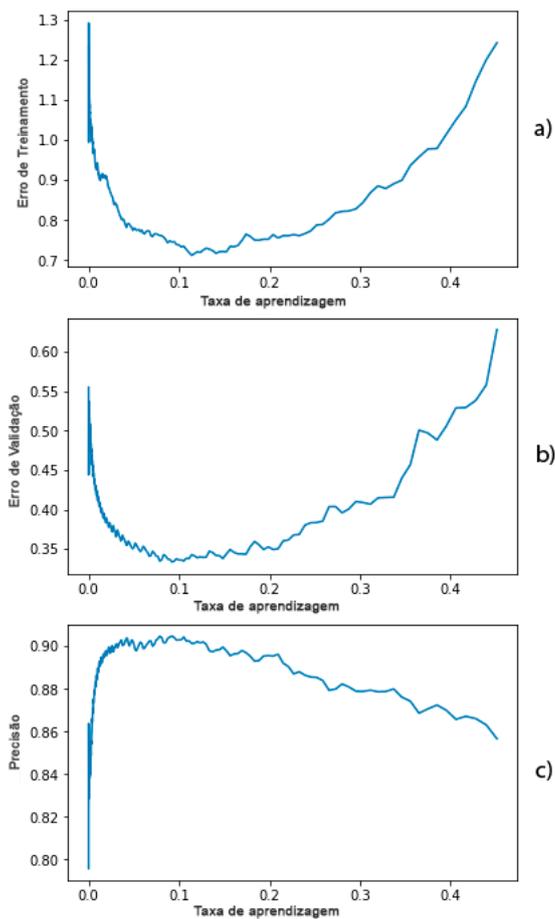


Figura 3.16 – Etapas de Treinamento (a), Validação (b) e Precisão (c) da abordagem de varredura para taxa de aprendizagem inicial dentro do intervalo testado de 10^{-22} a 10^1

3.3.1 Processo de treinamento para pragas primárias

No processo de treinamento LBP-SVM (EBRAHIMI et al., 2017), utilizou-se uma vizinhança local de 8 *pixels* e raio de 24, em que a precisão para as pragas primárias foi 24,6%. O método de treinamento da AlexNet é relativamente simples em relação ao tamanho da amostra, o processo de treinamento convergiu rapidamente, e a precisão do treinamento alcançou 94,8% em 30 épocas para o conjunto de imagens de pragas primárias, conforme mostrado na Figura 3.17. Logo no primeiro treinamento com 2 épocas observou-se a taxa de precisão de 89%, assim, aplicou-se a função de varredura, no intuito de encontrar a melhor taxa de aprendizagem para os treinamentos subsequentes. Em uma taxa 10^{-3} , a rede atingiu o seu ponto de saturação, não obtendo mais nenhum ganho significativo quanto à precisão no treinamento.

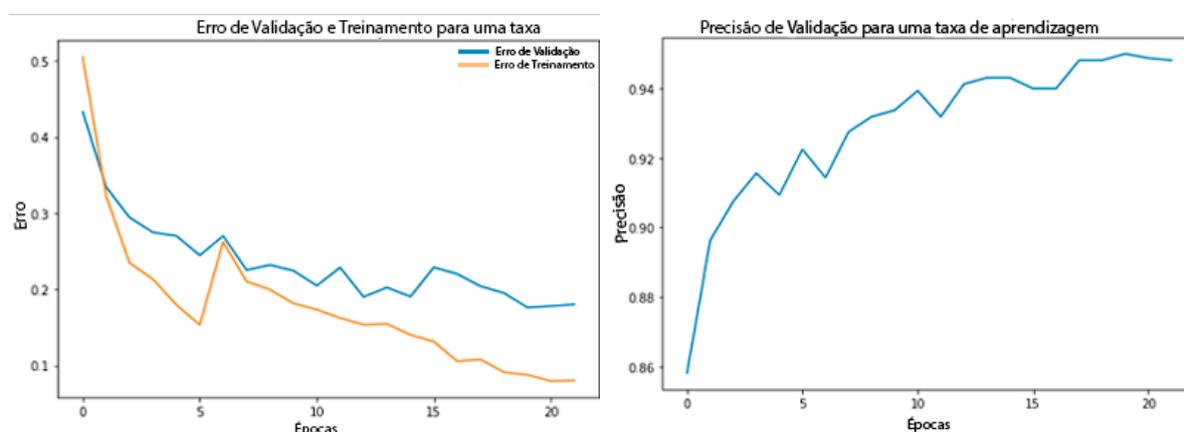


Figura 3.17 – Gráfico de erro de validação e treinamento com a precisão de validação da AlexNet (pragas primárias).

No treino da ResNet-34 padrão, pode ser observado que a técnica de regularização com *dropout* levou a rede a obter uma menor taxa de erro de validação em relação ao treinamento. No decorrer do método de treinamento, é aplicado a abordagem de varredura a fim de encontrar a melhor taxa de aprendizagem para iniciar o treinamento, a taxa 10^{-2} é escolhida e é iniciando o treinamento, com 2 épocas, a taxa de precisão de 94,9% é alcançada. Na segunda etapa do treinamento, a rede é subdividida em três grupos de camadas: nas primeiras camadas, é aplica uma taxa de aprendizagem 10^{-4} , nas camadas centrais, 10^{-3} e, nas camadas finais, 10^{-2} , alcançando 97.3% de precisão com 17 épocas. Assim como visto na Figura 3.18, o erro de treinamento atingiu o mínimo com um certo nível de oscilação, o que indica que o processo de treinamento deve parar na 17ª época, porque nenhuma melhoria adicional da RNC pode ser obtida nas últimas 3 épocas.

A ResNet-34* modificada segue os mesmos parâmetros de treinamento da Resnet-34 padrão, na 2ª época de treinamento, a sua precisão foi 88%, uma precisão menor se compara com a Resnet padrão. Ao analisar a Figura 3.20, é possível perceber a existência desta diferença de precisão. A saturação da rede é alcançada somente na 26ª época, com uma precisão de 97.8%, ou seja, devido ao maior número de classes de pragas, fez-se

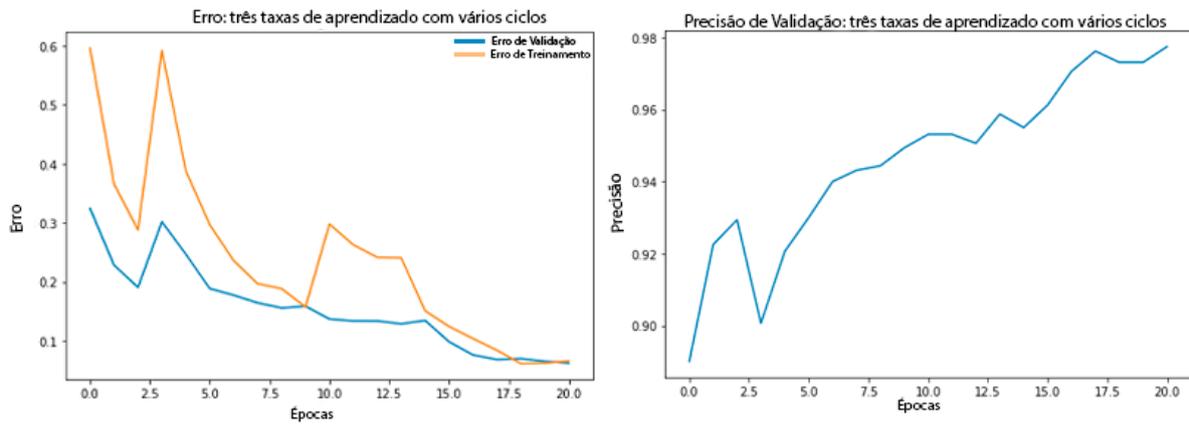


Figura 3.18 – Gráfico erro de validação e treinamento com a precisão de validação da ResNet-34 (pragas primárias).

necessário um maior número de interações para alcançar a saturação e com uma precisão superior.

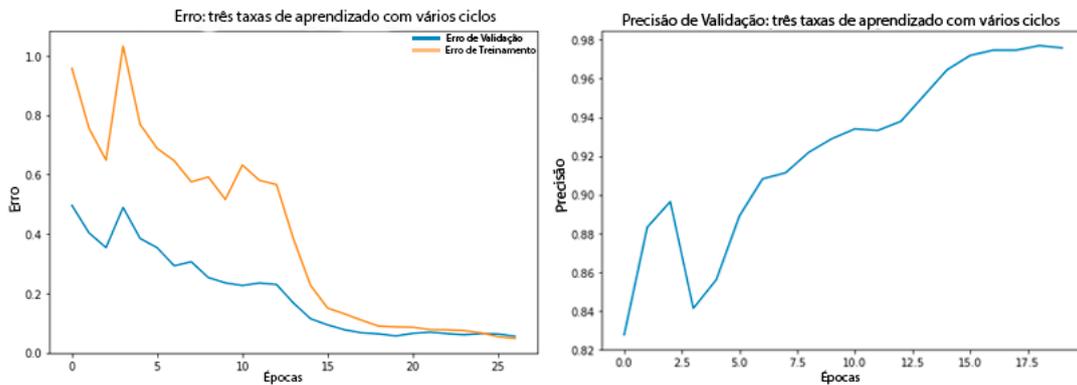


Figura 3.19 – Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-34* (pragas primárias).

O processo de treinamento da ResNet-50 utilizou-se do método similar empregado na ResNet-34 padrão, com um taxa de aprendizagem 10^{-2} e três épocas de treinamento. A sua precisão foi de 96.8% para o conjunto de pragas primárias, a precisão máxima de 97,3% foi atingida na 10^a época, com o seu ponto de saturação em uma aprendizagem de 10^{-3} , tornando o processo de treinamento mais rápido. Por outro lado, o seu custo computacional é maior que a ResNet-34.

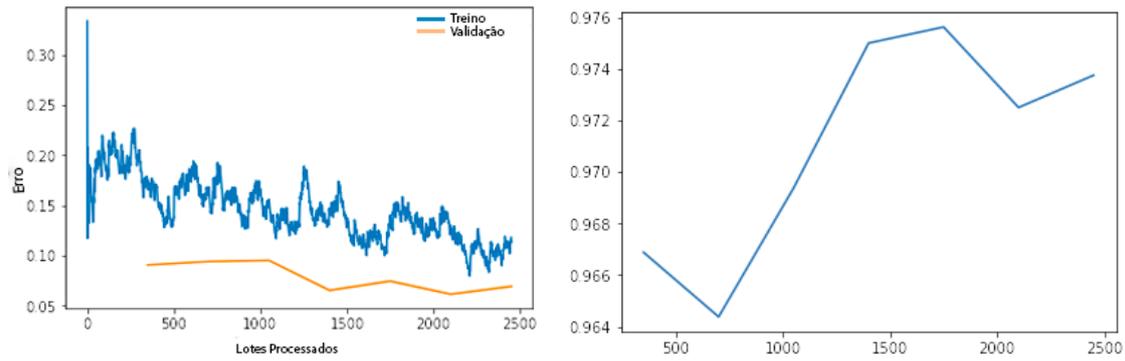


Figura 3.20 – Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-50 (pragas primárias).

3.3.2 Processo de treinamento para todas as pragas

No treinamento LBP-SVM para todas as pragas, utilizou-se o mesmo método realizados com pragas primárias, mas, de acordo com o aumento do número de classes de imagens, a sua precisão diminuiu para 20,1%. Em processo análogo de treinamento realizado na rede AlexNet padrão para o conjunto de pragas primárias, iniciou-se o treinamento para o conjunto de todas as pragas, no qual se obteve 94,7% de precisão nesse processo. A precisão do treinamento para todas as classes de pragas atingiu um máximo na 14^a época, como pode ser visto na figura 3.21 e, de modo idêntico às pragas primárias, atingiu o seu ponto de saturação com uma taxa de aprendizagem de 10^{-3} .

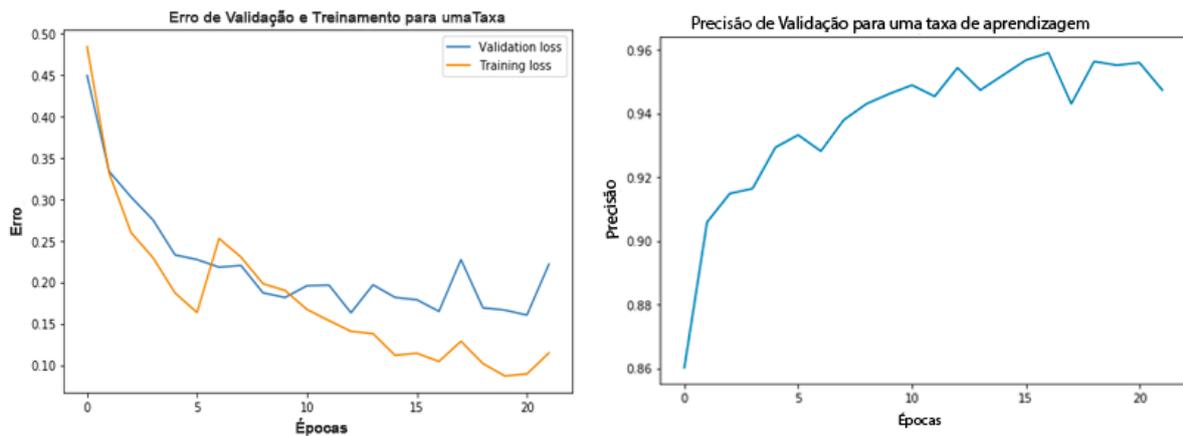


Figura 3.21 – Gráfico de erro de validação e treinamento com a precisão de validação da AlexNet (todas as pragas).

Em procedimento correlato à ResNet34 padrão no conjunto de pragas primárias, a ResNet-34 padrão, no conjunto de todas as pragas, teve praticamente o mesmo comportamento na 2^a etapa de treinamento. Com um taxa de aprendizagem 10^{-2} , a sua precisão foi de 87% e, a partir da 5^a época de treinamento, a rede é subdividida em três grupos de camadas. Nas primeiras camadas, é aplica uma taxa de aprendizado 10^{-4} , nas camadas centrais, 10^{-3} e, nas camadas finais, 10^{-2} . A precisão para ambas as classes começa a ser

uma crescente até atingir o valor máximo 98,7%, em 18 épocas, como pode ser visualizado na Figura 3.22.

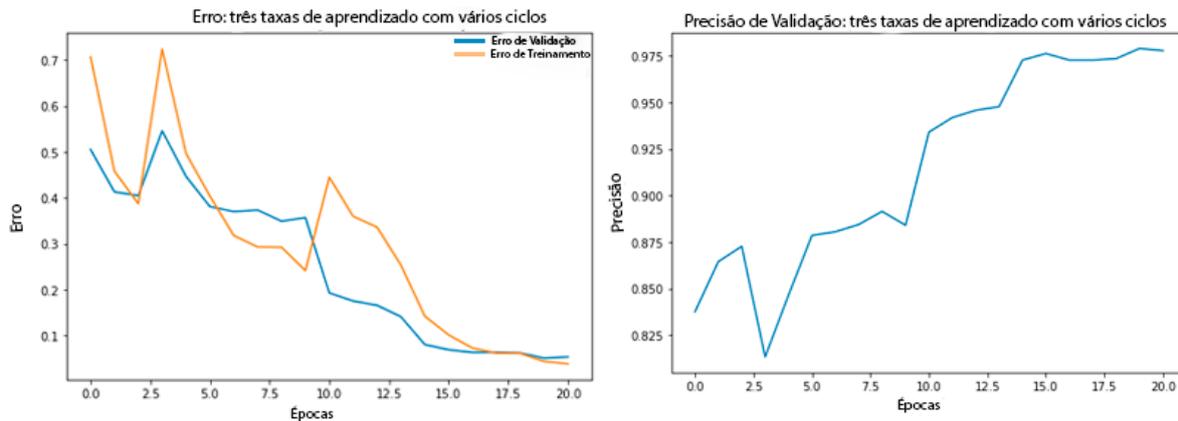


Figura 3.22 – Gráfico de erro de validação e treinamento com a precisão de validação da ResNet-34 (todas as pragas)

A precisão do treinamento para a ResNet-34* modificada no conjunto de todas as classes de pragas atingiu seu ponto máximo na 16^a época, com precisão de 98,1%, já a precisão do treinamento para as pragas primárias atingiu o seu máximo na 14^a época, e os parâmetros de treino seguiram o mesmos moldes realizados na ResNet-34 padrão. Até 13^a época, a taxa de aprendizagem de rede é 10^{-2} e, na 14^a interação, a rede é subdividida em três grupos de camadas. Nas primeiras camadas, é aplica uma taxa de aprendizagem 10^{-4} , nas camadas centrais, 10^{-3} e, nas camadas finais, 10^{-2} , e, apesar de a perda de precisão no treinamento continuou diminuindo, a taxa de mudança foi pequena. Depois de 17 épocas, a perda de treino atingiu o mínimo com um certo nível de oscilação, o que indica que o processo de treino deve parar na 14^a época, porque nenhuma melhoria adicional da RNC pode ser obtida nas últimas 6 épocas. A precisão da validação foi menor que a precisão do treinamento para as duas classes de pragas, como pode ser observado.

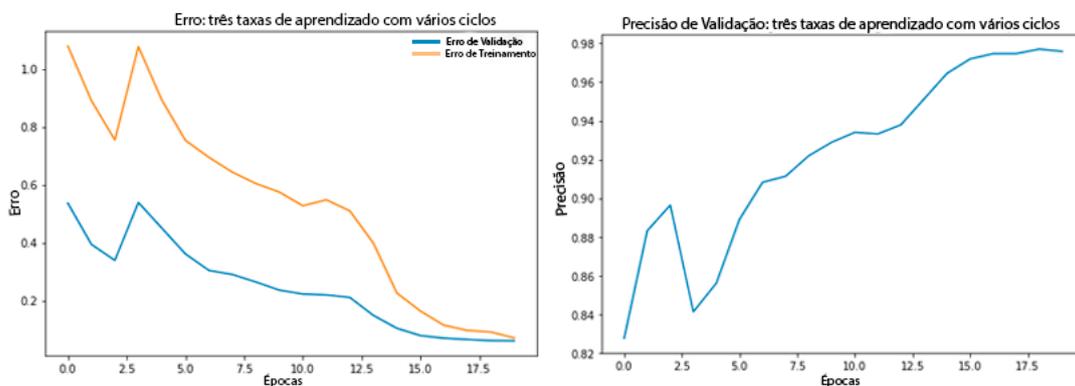


Figura 3.23 – Gráfico de erro de validação e treinamento com a precisão de validação da Resnet-34* (todas as pragas).

O processo de treinamento da ResNet-50 para as pragas primárias e secundárias praticamente seguiu o mesmo comportamento da ResNet-50 no conjunto de pragas primárias. Na 1^a etapa do treinamento, com um taxa de aprendizagem 10^{-2} com 3 épocas, a

sua precisão foi de 96,4%. Na 12ª época, com a taxa de aprendizagem 10^{-3} , a precisão começa a ser uma crescente, até atingir o valor de 97,4%.

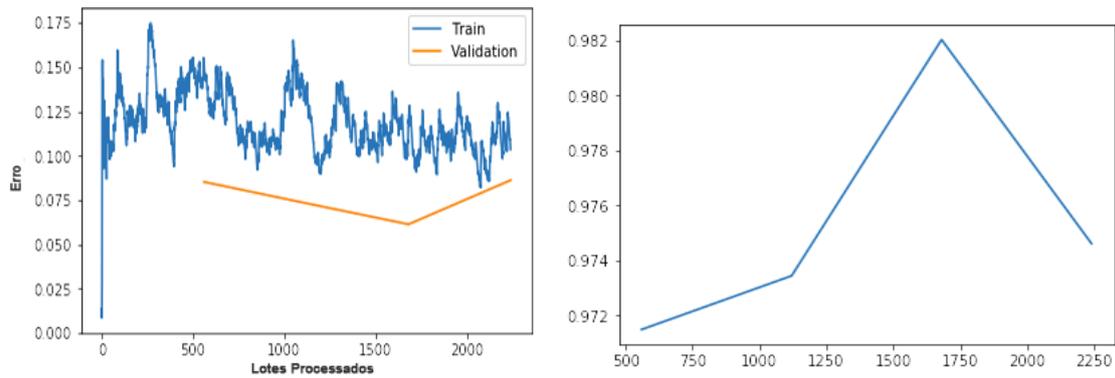


Figura 3.24 – Gráfico de erro de validação e treinamento com a precisão de validação da Resnet-50 (todas as pragas).

Neste capítulo detalhou-se como foi realizado o processo de organização do conjunto de dados de imagens de pragas do algodoeiro e como foi realizado o processo de treinamento das redes neurais para as versões da AlexNet, ResNet-34, ResNet-50 e Resnet-34*. Os resultados gerados pelos modelos serão mostrados no Capítulo Experimentos a seguir.

4 Experimentos e Análise dos Resultados

A abordagem realizada neste trabalho se deu no intuito de resolver dois diferentes problemas de classificação. O primeiro refere-se a um conjunto de nove pragas primárias mais uma de imagens de plantação de algodão sem pragas. O segundo refere-se a tarefa de classificação de dezesseis classes, composta por espécies de pragas primárias e secundárias, mais uma classe de imagens de não pragas. Contudo, todas as problemáticas supramencionadas foram executadas e implementadas utilizando um computador com suporte GPU (NVIDIA GTX 1060 6GB), processador i7, uma biblioteca de aprendizagem profunda Fastai (HINTON; OSINDERO; TEH, 2006) com *backend pytorch*, usando os pesos pré-treinados da ImageNet, que possui mais de 1 milhão de imagens e 1000 classes, assim, abordou-se a aprendizagem supervisionada com *transfer learning*.

4.1 Experimentos

No primeiro experimento, as redes classificaram as seis pragas primárias *Anthonomus grandis*, *Aphis gossypi*, *Helicoverpa armigera*, *Heliothis virescens*, *Pseudoplusia includens*, *Spodoptera frugiperda*, com adição das fases adultas de três delas, *Helicoverpa armigera adulta*, *Heliothis virescens adulta*, *Spodoptera frugiperda adulta*, (ilustrado na Figura 3.4 - Materiais e Métodos) e uma classe não praga.

Foram usados no primeiro experimento 7200 imagens de pragas primárias de campo do algodoeiro, dividindo o conjunto de dados, de forma aleatória, em 80% para treinamento e 20% teste, e um modelo LBP (EBRAHIMI et al., 2017), seguido por Máquina de vetores de Suporte (SVM) com *kernel* linear. Realizou-se o teste do LBP-SVM contra um modelo típico de RNC (AlexNet), no intuito de comparação, embora os testes foram realizados também com arquiteturas de redes residuais: ResNet-34, um modelo proposto da ResNet-34* modificada e a ResNet-50. Pode ser observar os valores reais e valores preditos pelos classificadores nas matrizes de confusão apresentadas pelas Figuras 4.1, 4.2, 4.3, 4.4 e 4.5, em que ainda observa-se nos resultados apresentados nas matrizes de confusão há ausência de espelhamento entre classes potencialmente confundíveis. Isso se deu possivelmente em virtude da combinação de transformações aleatoriamente aplicadas em cada imagem.

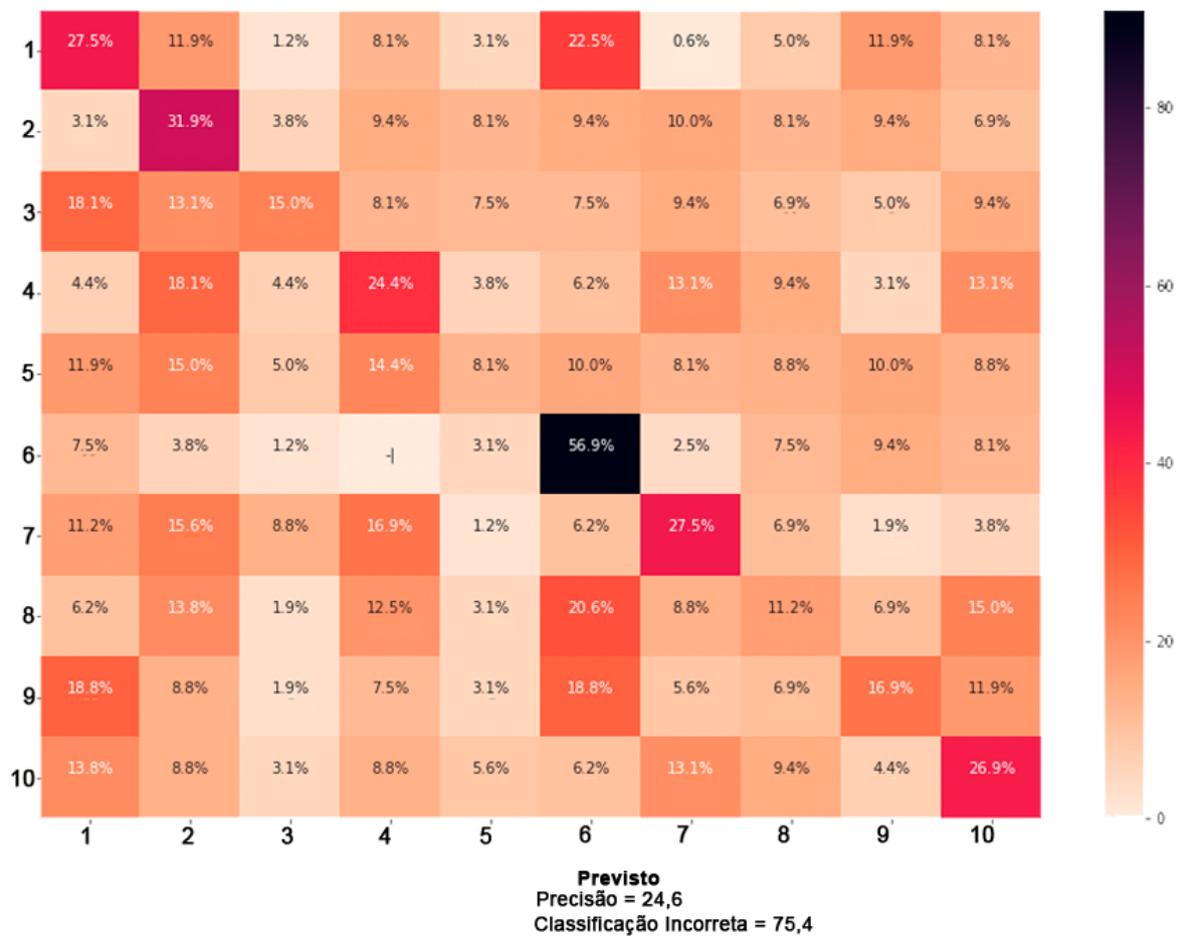


Figura 4.1 – Matriz de confusão gerada pelo classificador LBP-SVM, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) *Não Praga*, 10) *Pseudoplusia includens*.



Figura 4.2 – Matriz de confusão gerada pelo classificador AlexNet, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) *Não Praga*, 10) *Pseudoplusia includens*.

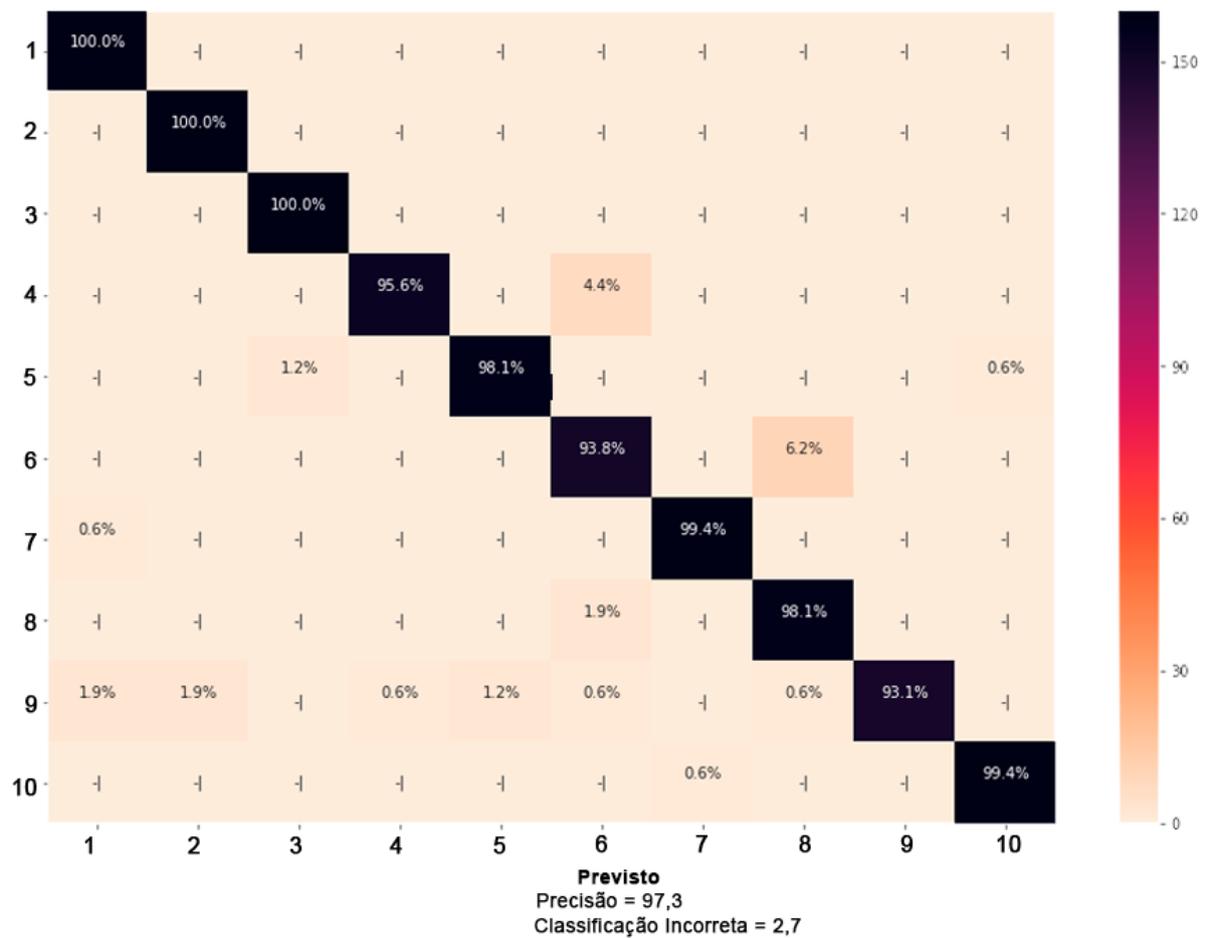


Figura 4.3 – Matriz de confusão gerada pelo classificador ResNet-34, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) *Não Praga*, 10) *Pseudoplusia includens*, 11)

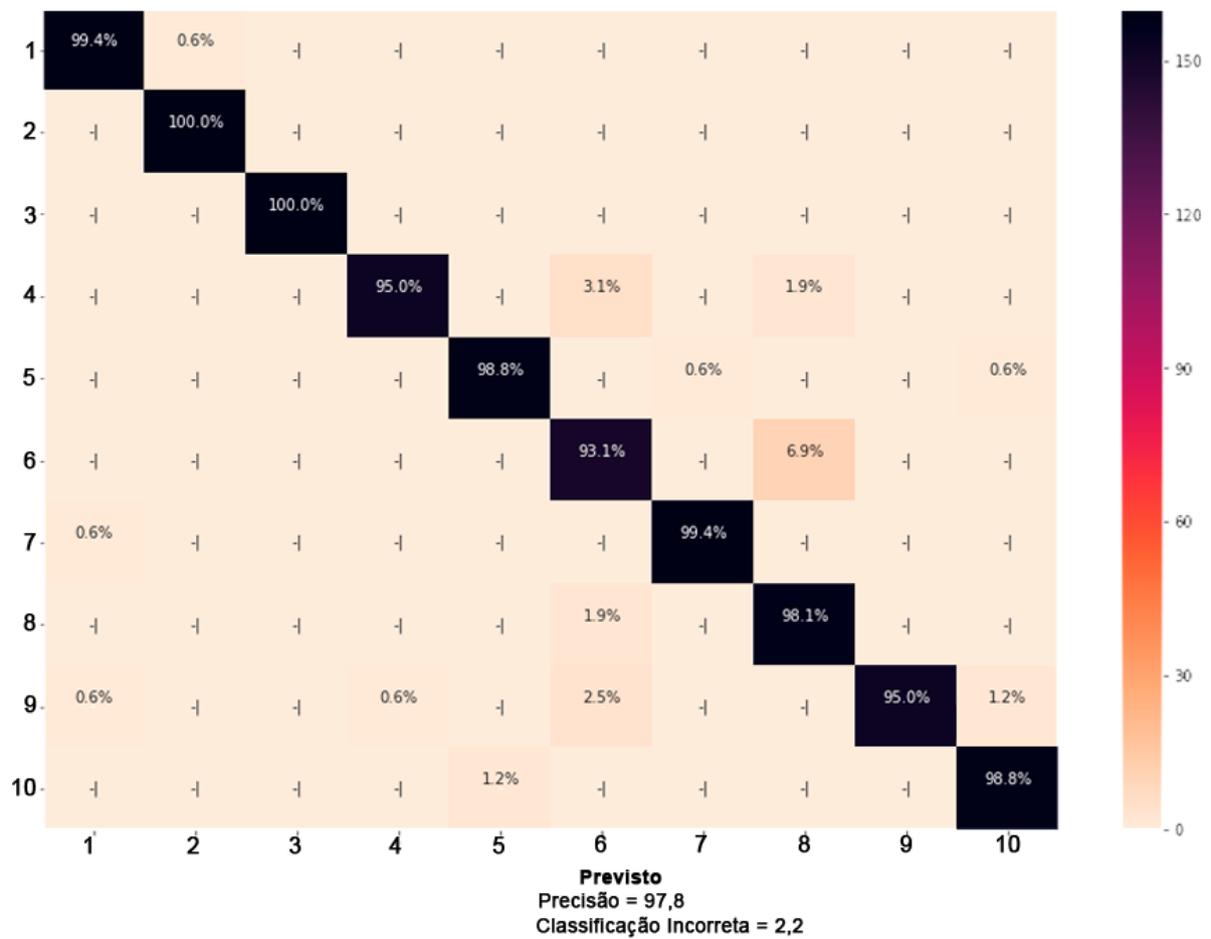


Figura 4.4 – Matriz de confusão gerada pelo classificador ResNet-34*, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) *Não Praga*, 10) *Pseudoplusia includens*, 11).

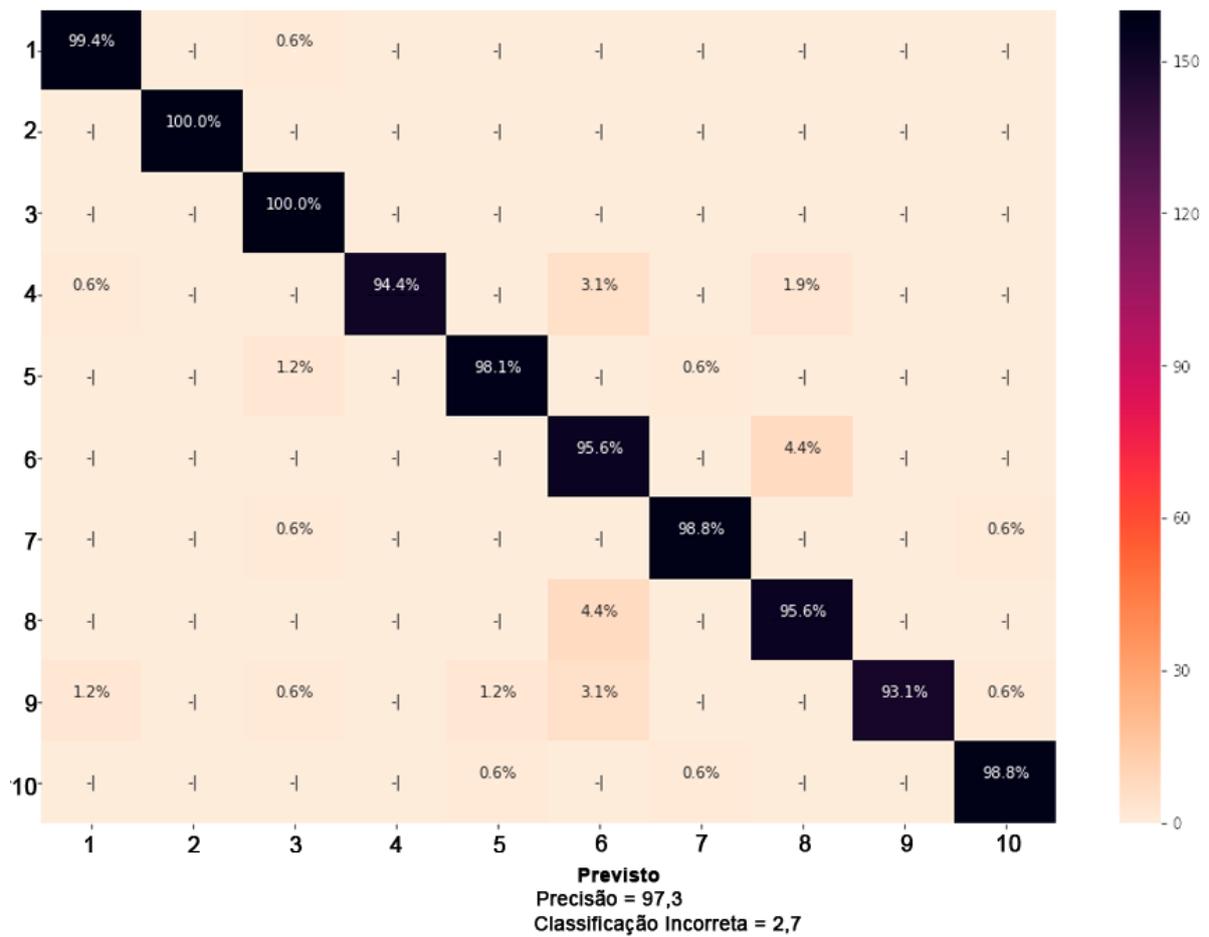


Figura 4.5 – Matriz de confusão gerada pelo classificador ResNet-50, para o conjunto de imagens de pragas primárias, com os seguintes descritores: 1) *Anthonomus grandis*, 2) *Aphis gossype*, 3) *Helicoverpa amigera*, 4) *Helicoverpa amigera adulta*, 5) *Heliothis virescens*, 6) *Heliothis virescens adulta*, 7) *Spodoptera frugiperda*, 8) *spodoptera frugiperda adulta*, 9) *Não Praga*, 10) *Pseudoplusia includens*, 11).

A Tabela 3 fornece as taxas de precisão obtidas no primeiro experimento para cada um dos modelos propostos. Todos os modelos RNC mostraram-se bem acima da LBP-SVM, com maior precisão média alcançada pela ResNet34* modificada.

Tabela 3 – Desempenho (precisão) de cada modelo por classe (%): primária e não pragas.

Classe	LBP-SVM	AlexNet	ResNet-34	ResNet-34*	ResNet-50
<i>Anthonomus grandis</i>	27.5	96.6	100	99.4	99.4
<i>Aphis gossypii</i>	31.9	99.4	100	100	100
<i>Helicoverpa armigera</i> (larva)	15.0	98.1	100	100	100
<i>Helicoverpa armigera</i> (adulto)	24.4	93.1	95.6	95.0	94.4
<i>Heliothis virescens</i> (larva)	8.1	96.2	98.1	98.8	98.1
<i>Heliothis virescens</i> (adulto)	56.9	88.8	93.8	93.1	95.6
<i>Pseudoplusia includens</i>	27.5	99.4	99.4	98.8	98.8
<i>Spodoptera frugiperda</i> (larva)	11.2	98.1	99.4	99.4	98.8
<i>Spodoptera frugiperda</i> (adulto)	16.9	95.6	98.1	98.1	95.6
Não praga	26.9	83.8	93.1	95.0	93.1
Média	24.6	94.8	97.3	97.8	97.3

Para o segundo experimento, o conjunto de dados é constituído da junção do conjunto de pragas primárias (*Anthonomus grandis*, *Aphis gossypii*, *Helicoverpa armigera*, *Heliothis virescens*, *Pseudoplusia includens*, *Spodoptera frugiperda* com adição das fases adultas de três delas *Helicoverpa armigera adulta*, *Heliothis virescens adulta*, *Spodoptera frugiperda adulta*), ilustradas na Figura 3.4, mais o conjunto de pragas secundárias (*Alabama argillacea*, *Bemisia tabaci*, *Horcias nobilellus*, *Pectinophora gossypiella*, *Spodoptera eridania* e *Tetranychusurtica*), demonstrado na Figura 3.5, e uma classe de não pragas.

Foram usadas para avaliar os quatro modelos de RNC: AlexNet, ResNet-34, ResNet-50 e a ResNet-34*(modificada) um total de 11.520 imagens, ressaltando-se que o banco de dados de imagens é balanceado, tendo 720 imagens por classe de praga e uma classe de não praga. A Tabela 4 fornece os resultados completos de precisões das redes para o conjunto de imagens supramencionado. Todos os modelos de RNC obtiveram ótimos resultados de precisão, com uma pequena vantagem para os modelos residuais (ResNet-34, ResNet-34* e ResNet-50) em relação à rede AlexNet, em que a ResNet-34* obteve uma precisão de 98,1%, como pode ser analisado nas matrizes de confusões gerada pelos classificadores ilustrados nas Figuras 4.6 4.7, 4.8, 4.9 e 4.10, em que os resultados apresentados nas matrizes de confusão há ausência de espelhamento entre classes potencialmente confundíveis. Isso se deu possivelmente em virtude da combinação de transformações aleatoriamente aplicadas em cada imagem.

Tabela 4 – Desempenho (precisão) de cada modelo por classe (%): Todas as pragas e não praga.

Classe	LBP-SVM	AlexNet	ResNet-34	ResNet-34*	ResNet-50
<i>Anthonomus grandis</i>	16.9	94.4	98.1	99.4	98.8
<i>Aphis gossypii</i>	19.4	100	100	99.4	98.8
<i>Helicoverpa armigera</i> (larva)	9.4	96.9	100	100	100
<i>Helicoverpa armigera</i> (adulto)	16.2	91.2	95.6	93.8	93.1
<i>Heliothis virescens</i> (larva)	7.5	100	100	98.8	95
<i>Heliothis virescens</i> (adulto)	57.5	81.9	91.2	98.1	89.4
<i>Pseudoplusia includens</i>	31.9	97.5	99.4	100	98.8
<i>Spodoptera frugiperda</i> (larva)	8.1	97.5	100	99.4	99.4
<i>Spodoptera frugiperda</i> (adulto)	32.5	100	93.8	90.6	100
<i>Alabama argillacea</i>	16.9	98.1	100	100	98.8
<i>Bemisia tabaci</i>	11.2	98.8	100	100	98.8
<i>Horcias nobilellus</i>	41.2	98.1	100	100	100
<i>Pectinophora gossypiella</i>	6.2	99.4	100	100	100
<i>Spodoptera eridania</i>	6.2	95.6	98.8	98.8	98.1
<i>Tetranychus urticae</i>	16.9	93.8	95.6	91.9	97.5
Não praga	15.0	72.5	91.1	93.5	93.1
Média	20.1	94.7	97.7	98.1	97.4

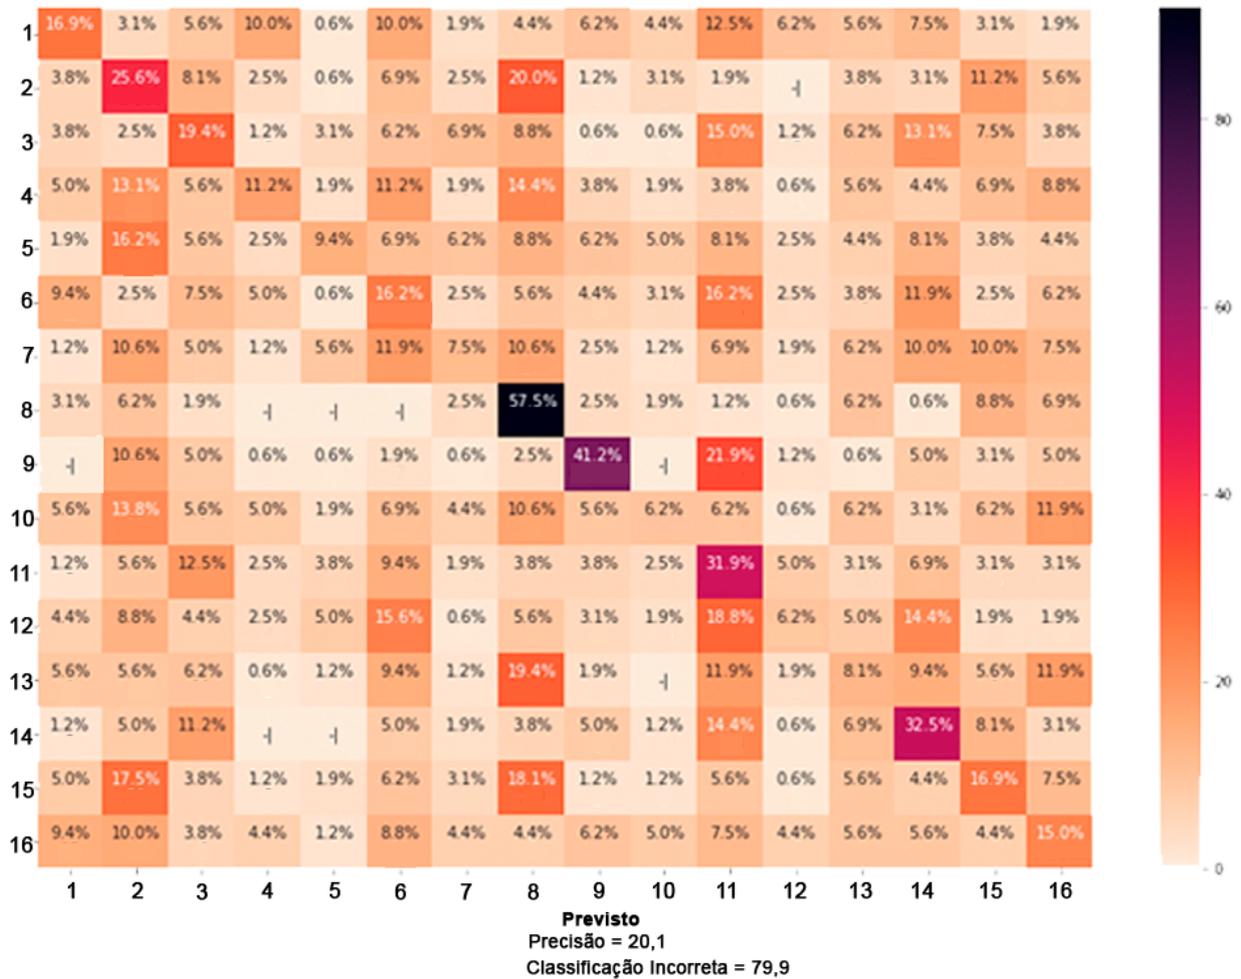


Figura 4.6 – Matriz de confusão gerada pelo classificador LBP-SVM, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) *Não Praga*, 16) *Pseudoplusia includens*.

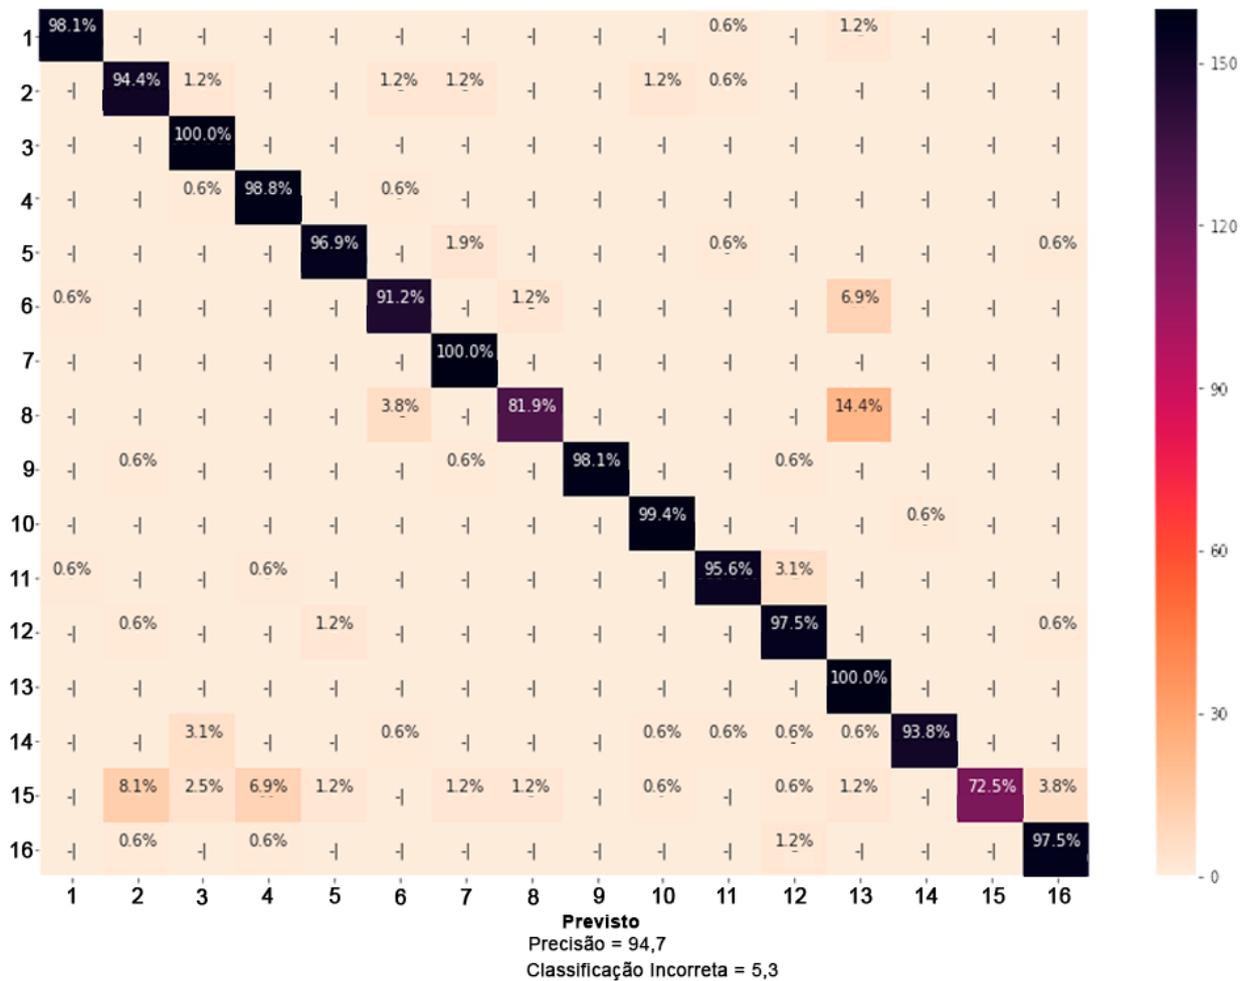


Figura 4.7 – Matriz de confusão gerada pelo classificador AlexNet, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) *Não Praga*, 16) *Pseudoplusia includens*.

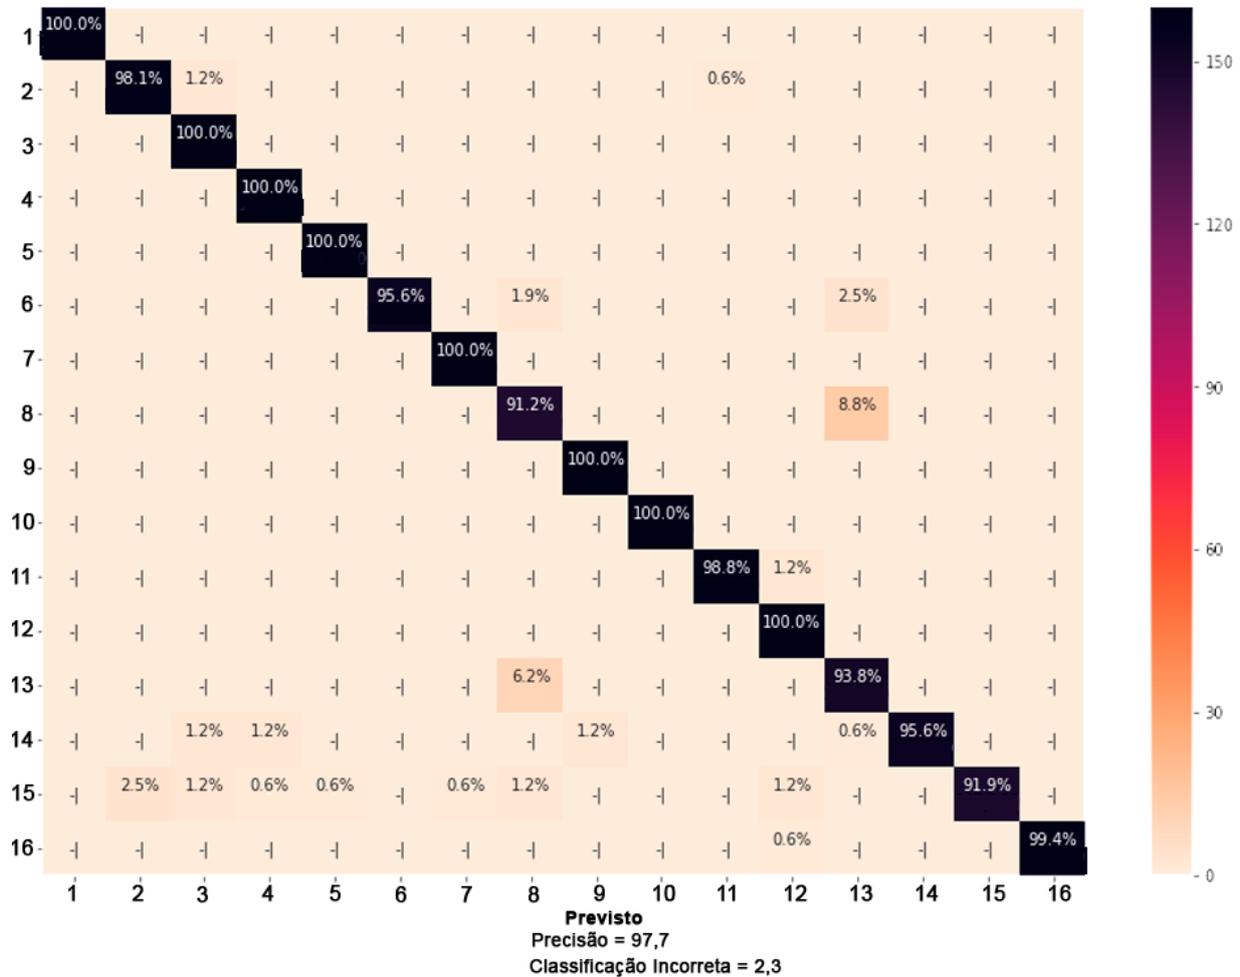


Figura 4.8 – Matriz de confusão gerada pelo classificador ResNet-34, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) *Não Praga*, 16) *Pseudoplusia includens*.

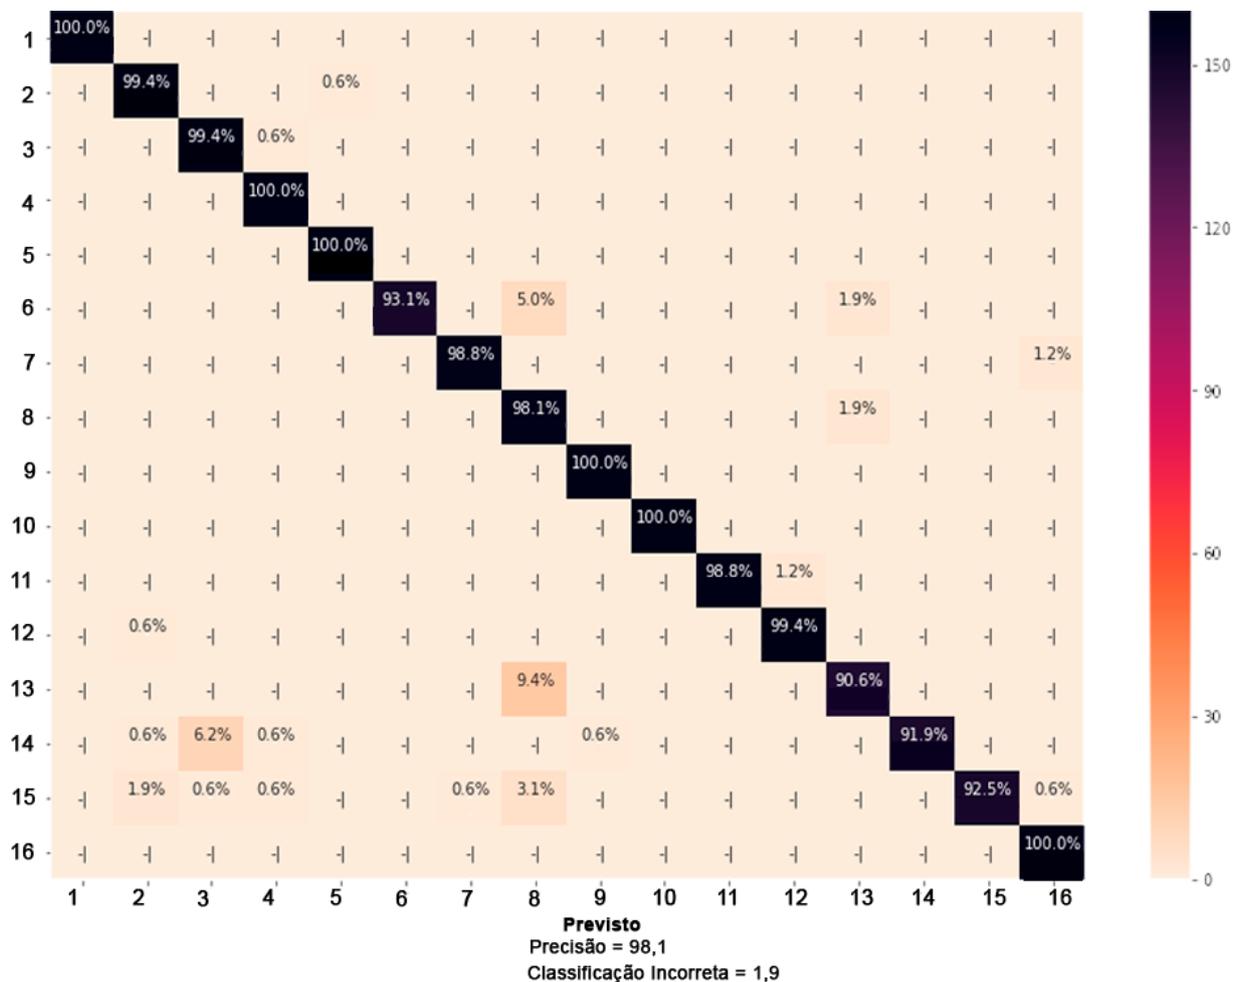


Figura 4.9 – Matriz de confusão gerada pelo classificador ResNet-34*, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) *Não Praga*, 16) *Pseudoplusia includens*.

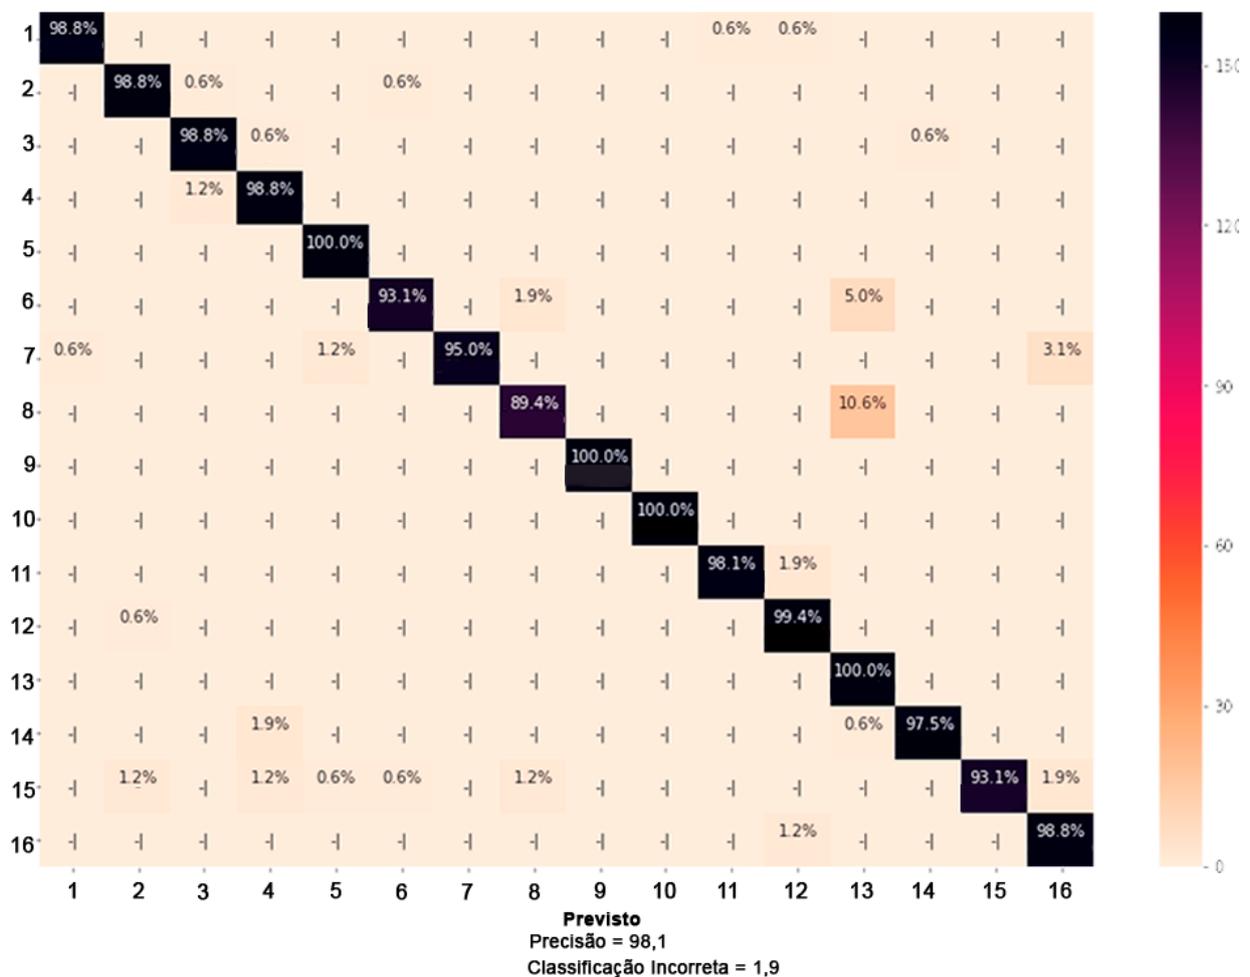


Figura 4.10 – Matriz de confusão gerada pelo classificador ResNet-50, para o conjunto de imagens de todas as pragas, com os seguintes descritores: 1) *Alabama argillacea*, 2) *Anthonomus grandis*, 3) *Aphis gossype*, 4) *Bemisia tabaci*, 5) *Helicoverpa amigera*, 6) *Helicoverpa amigera adulta*, 7) *Heliothis virescens*, 8) *Heliothis virescens adulta*, 9) *Horcias nobilellus*, 10) *Pectinophora gossypiella*, 11) *Spodoptera eridania*, 12) *Spodoptera frugiperda*, 13) *spodoptera frugiperda adulta*, 14) *Tetranychus urticae*, 15) *Não Praga*, 16) *Pseudoplusia includens*.

As Figuras 4.11 e 4.12 fornecem a média de precisão (medidas F ou F -scores) para os modelos RNC e trazem informações para ambos os experimentos. As redes permaneceram abaixo de um F -score de 0,94 na classe *Heliothis virescens* (adulta) e *Spodoptera frugiperda* (adulta).

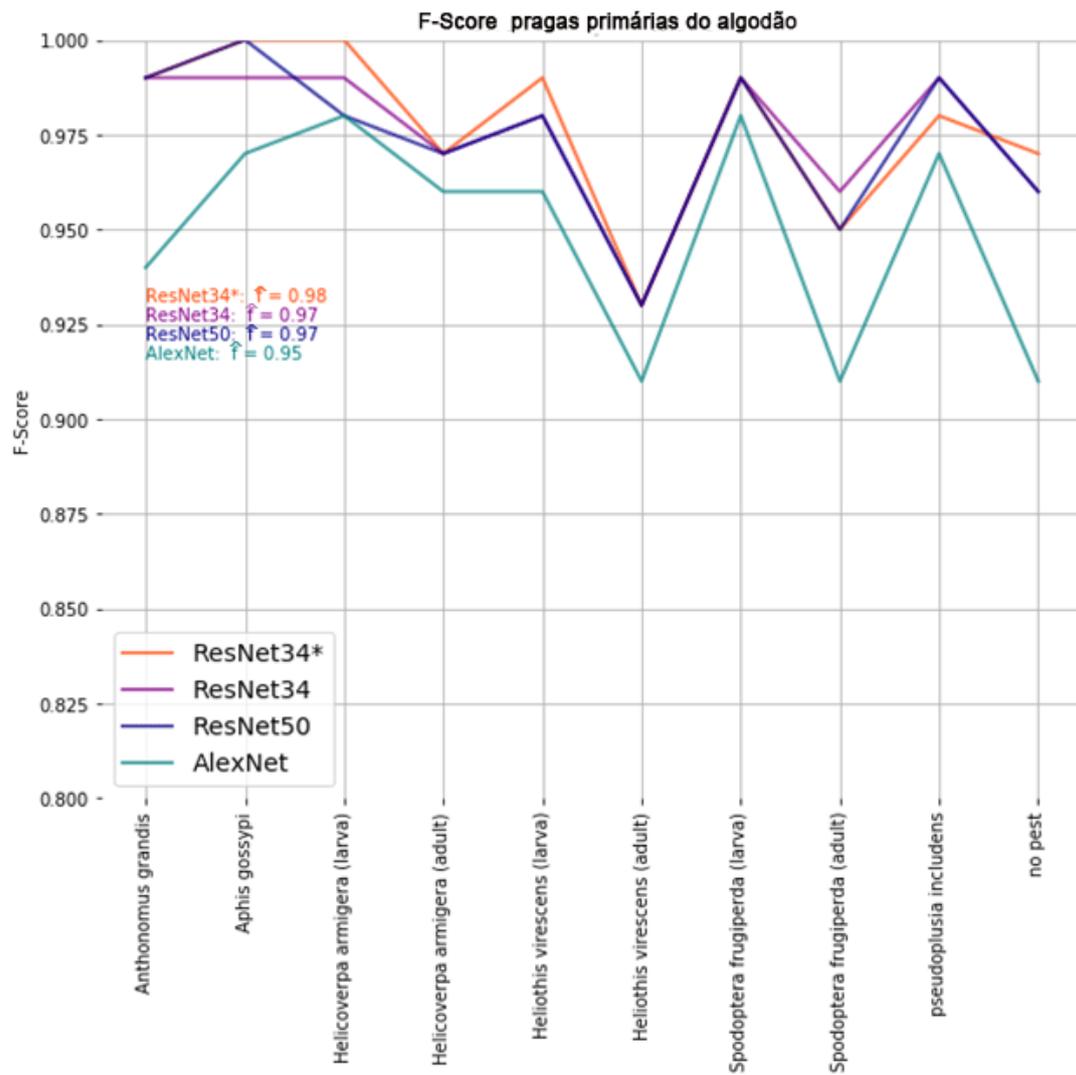


Figura 4.11 – F-score \hat{f} valores do primeiro experimento: (1^o) pragas primárias

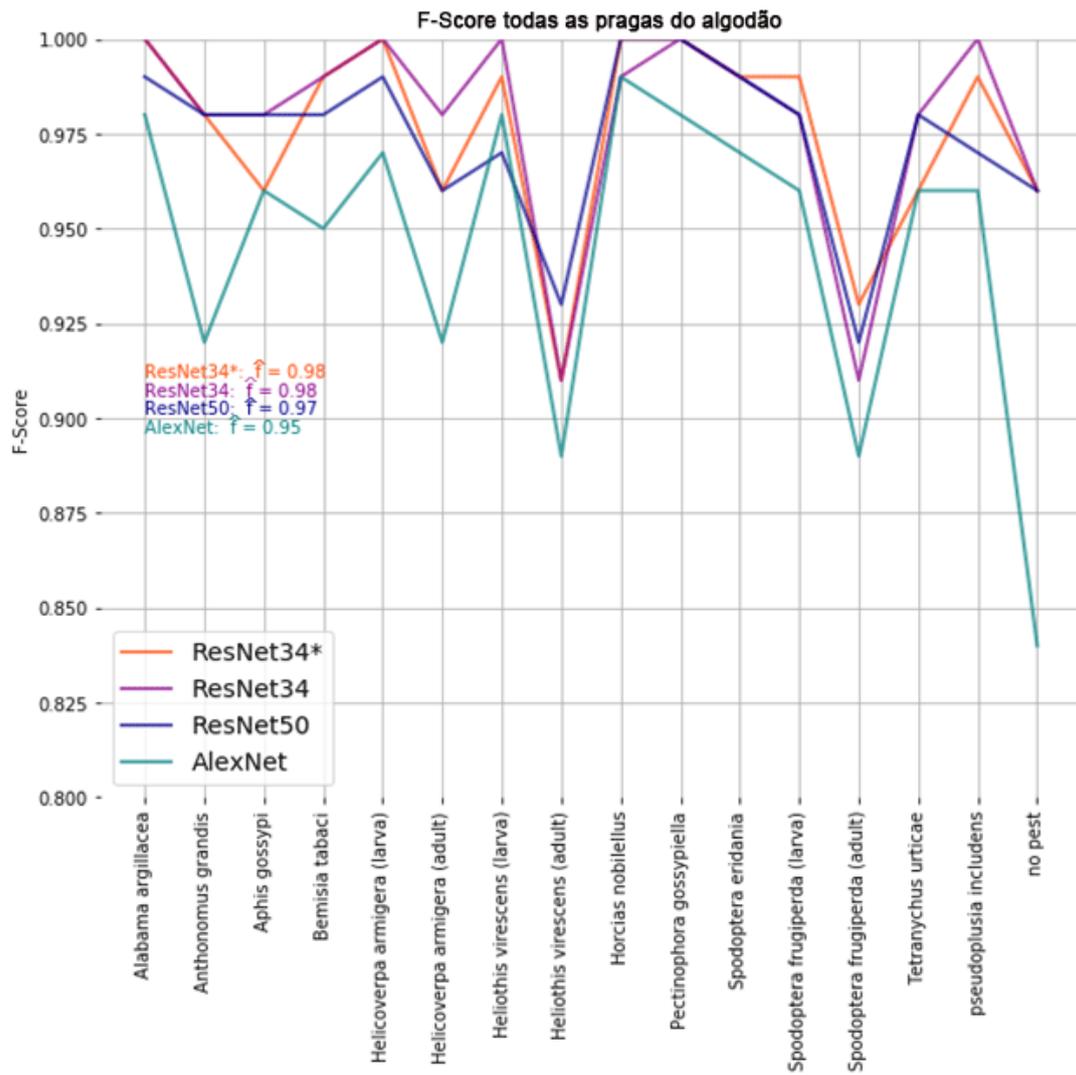


Figura 4.12 – F-score \hat{f} valores do segundo experimentos: (2º) pragas primárias e secundárias do algodão.

A ResNet-34* foi projetada principalmente para superar o problema de sobreajuste (*overfitting*). Uma normalização inicial, com 1024 valores de ativação (512 de pré-treinados e outros 512 gerados aleatoriamente), acelera o decaimento da perda. Além disso, também adiciona novos valores possíveis para o treinamento (512 novos pesos aleatórios). A camada anterior é seguida por um descarte agressivo de 70%, que é a primeira tentativa de reduzir o *overfitting*. Uma camada linear traz de volta o número de ativações para 512, como na ResNet-34 original, mas agora é seguido por outro descarte (*dropout*) de 50%, para reduzir *overfitting* nas últimas épocas da sessão de treinamento.

4.2 Análise de Resultados

Esta seção analisa os resultados obtidos nos testes de classificação utilizando um modelo clássico (LBP-SVM) *versus* modelos de redes neurais convolucionais (AlexNet, Resnet-34, Resnet-50 e Resnet-34*) em um conjunto de dados de imagens de pragas de campo da cultura do algodão.

A identificação automatizada de insetos tem sido intensamente estudada nas últimas três décadas, incluindo sistemas baseados em Visão Computacional para classificação de espécies de insetos.

De modo geral, as redes neurais convolucionais mostraram ser altamente precisas em suas previsões. Embora o conjunto de dados proposto seja maior do que qualquer outro relatados (MARTINEAU et al., 2017), com o intuito de melhorar ainda mais a precisão para algumas classes, um conjunto de dados maior seria capaz de auxiliar nesse processo. Como observado, especialmente em plantações tropicais em que o número de espécies de insetos pode ser bem maior, uma mudança no número de classes e a precisão para o modelo proposto devem ser investigadas. A ResNet-34* proposta é um exemplo de um modelo de sucesso considerando esses aspectos.

Na primeira experiência, há a abordagem utilizando o modelo clássico de SVM (*Support Vector Machine*) alimentado pelo LBP (*Local Binary Pattern*), no intuito de realizar testes comparativos de precisão de classificação de classe de pragas com os modelos de redes neurais convolucionais (RNCs). Na classificação em um conjunto de seis pragas primárias *versus* imagens de plantação sem pragas, o LBP-SVM consegue obter o melhor desempenho de classificação para a classe de praga *Heliothis virescens* (adulta), atingindo uma precisão de 56.9% e, ainda, uma precisão baixa em relação ao pior desempenho das RNCs para a mesma classe praga, que é 88.8%, como pode ser visto na Tabela 3.

A *Heliothis virescens* (adulta) foi, em média, a classe mais difícil de categorizar no primeiro experimento. As diferenças visuais para esta classe são de fato muito sutis, pois possuem como características pequenas manchas nas asas além das outras.

O modelo proposto, que é a ResNet-34*, atingiu uma precisão de 98,1% para a

proposta de classificação de dezesseis classes composta por espécies de pragas primárias e secundárias, mais uma classe de imagens de plantação sem pragas, enquanto as outras arquiteturas de redes neurais convolucionais residuais atingiram os seguintes resultados, dados notados pela Tabela 4. : ResNet-34 (97.7%) e ResNet-50 (97.4%).

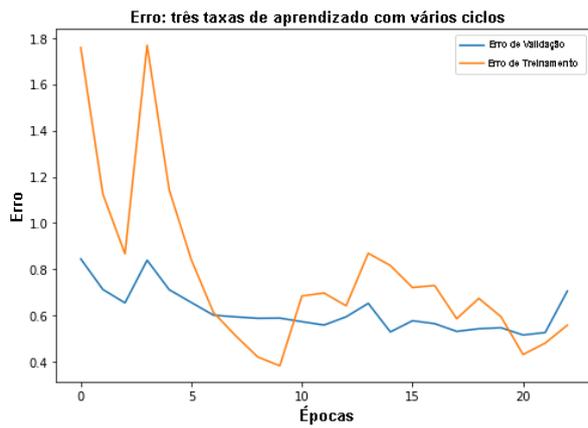
Ao observar as imagens 4.11 e 4.12 visualiza-se que as redes neurais convolucionais permaneceram uma média de relevância quanto a precisão (*F-scores*) abaixo 0,94 na classe *Heliopsis virences* (adulto) pois foi em grande parte erroneamente classificada com *Spodoptera frugiperda* (adulto).

Para fins de análise de sobreajuste e validação do método de ampliação do conjunto de imagens, realizou-se um teste somente como as imagens originais das 15 categorias de pragas e 1 não praga, totalizando 1600 imagens. Com esse teste, pode-se comparar seus resultados com aquele obtido pelo conjunto de dados de imagens ampliadas.

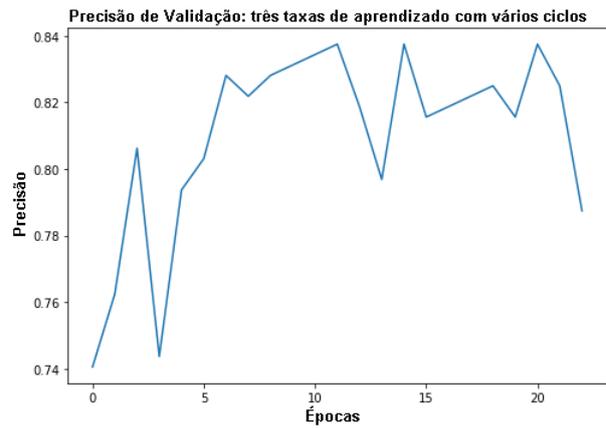
Neste comparativo utilizou-se a rede ResNet-34* para ambos os conjuntos, a Figura 4.13 demonstra que o desempenho da rede ResNet-34* para o conjunto original segue padrão semelhante ao comportamento do mesmo obtido para o conjunto ampliado.

Observa-se também que os resultados descritos para o conjunto de imagens originais tem variação mais abrupta pelo fato do conjunto ser menor em relação ao conjunto de dados ampliados.

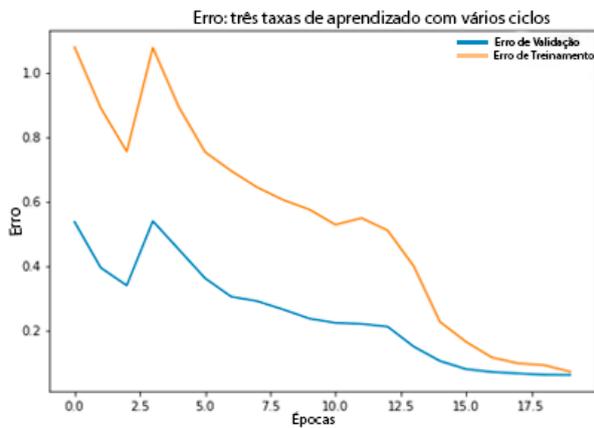
No próximo capítulo são resumidas as conclusões.



(a)



(b)



(c)



(d)

Figura 4.13 – Resultados Comparativos de erro e precisão da ResNet-34*: a) e b) para conjunto de imagens originais, c) e d) conjunto de dados ampliados.

5 Conclusões

Este trabalho apresentou um novo conjunto de imagens (*dataset*) de pragas de algodão, baseadas em campo com 1.600 imagens originais para quinze classes de pragas de algodão (sendo 3 classes diferenciadas entre inseto larva e inseto adulto) mais comuns e uma classe de não pragas, todas elas balanceadas. Com o uso do *augmentation*, o conjunto de dados passa a ter 11.520 imagens adequadas para tarefas de reconhecimento. Portanto, este é o maior conjunto de dados para o problema proposto quando comparado aos conjuntos de pragas em campo aberto já relatados.

Reconhecimento de insetos, considerando somente imagens de campo, e ainda com foco particular em uma cultura, é um desafio baseado em classificação visual. Além de comparar uma base de classificadores constituídos de: um LBP, seguido por um classificador SVM, redes RNC (AlexNet) e redes residuais como os modelos (ResNet-50, ResNet-34), também foi proposto um modelo modificado (ResNet-34 *). A ResNet-34* é um modelo modificado proposto, que apresentou melhor precisão na validação cruzada em média geral (98,1%) do que qualquer outro e suas modificações poderiam ser aplicadas e analisadas posteriormente para conjuntos de dados estendidos. Apesar da ResNet-34* apresentar o melhor convergência devido a adição das camadas de *dropout*, as quais foram adicionadas para promover a generalização das classificações do modelo, as camadas de *batch normalization* não resultaram na proposta inicial de redução do número de épocas, entretanto suavizaram as curvas de erro durante o treinamento. Os resultados obtidos com ambas os modelos de redes de aprendizagem profunda certificam a eficácia do uso de uma RNC no processo de reconhecimento de pragas em ambiente de terras agrícolas, cuja a precisão de classificação da AlexNet é (94,7%), ResNet-34 (97,4%) e ResNet-50 (97,4%).

A *Heliothis virescens* (adulto) foi, em média, a classe mais difícil de categorizar pelas redes neurais convolucionais. As suas diferenças visuais (padrões geométricos, cor e textura) para esta classe são, de fato, muito sutis, não fornecendo características suficientes para que as redes possam diferenciá-la das outras fases adultas da *Spodoptera frugiperda* e *Helicoverpa amigera*. Algumas das possíveis tentativas para reduzir a sobreposição de classificação das classes de pragas supramencionadas, poderia ser abrangendo um maior número de imagens por classes, caso não havendo maior rendimento, uma outra alternativa seria aumentar a resolução de entrada das redes, bem como a resolução das imagens do conjunto de treinamento, favorecendo a detecção de características as quais distinguem as

classes.

Além do domínio de aplicação estar direcionado para a classificação de classes de pragas usando imagens de campo pertencentes à cultura do algodão, a solução poderá ser adaptada para outros domínios com o mesmo tipo de dinâmica em que se exija realizar a utilização de um classificador baseado em aprendizagem de máquinas.

Como trabalhos futuros, ampliar o conjunto de dados, adicionando novas amostras e outras classes de insetos constituídas de inimigos naturais e insetos inofensíveis ao cultivo do algodão, poderia ser um objetivo em conjunto com outras culturas e seus devidos ecossistemas relacionados. A comparação com outros modelos de rede utilizando o mesmo conjunto de dados para avaliar o desempenho do classificador. Melhorar o resultado dessa dissertação, por meio de novas arquiteturas, treino de redes profundas do zero, uso de outros mecanismos de regularização e otimização.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, L. R. A. et al. Produção e exportação de algodão: efeitos de choques de oferta e de demanda. *Revista Brasileira de Economia*, SciELO Brasil, v. 62, n. 4, p. 381–405, 2008.
- CHAPMAN, A. D. et al. Numbers of living species in australia and the world. Department of the Environment, Water, Heritage and the Arts Canberra, 2009.
- CHEN, X. et al. Vehicle detection in satellite images by hybrid deep convolutional neural networks. *IEEE Geoscience and remote sensing letters*, IEEE, v. 11, n. 10, p. 1797–1801, 2014.
- CHENG, X. et al. Pest identification via deep residual learning in complex background. *Computers and Electronics in Agriculture*, Elsevier, v. 141, p. 351–356, 2017.
- CO-OPERATION, O. for E.; DEVELOPMENT. *OECD-FAO Agricultural Outlook 2016-2025 (Chinese version)*. Paris: OECD Publishing, 2016.
- EBRAHIMI, M. et al. Vision-based pest detection based on svm classification method. *Computers and Electronics in Agriculture*, Elsevier, v. 137, p. 52–58, 2017.
- EFRON, B. The efficiency of logistic regression compared to normal discriminant analysis. *Journal of the American Statistical Association*, Taylor & Francis, v. 70, n. 352, p. 892–898, 1975.
- FAITHPRAISE, F. et al. Automatic plant pest detection and recognition using k-means clustering algorithm and correspondence filters. *International Journal of Advanced Biotechnology and Research*, BioIT InternationalsJournals, v. 4, n. 2, p. 189–199, 2013.
- FERNANDES, M. G. et al. Natural parasitism of alabama argillacea hüb. and heliothis virescens fab.(lep.: Noctuidae) by trichogramma pretiosum riley (hym.: Trichogrammatidae) on cotton in the state of mato grosso do sul. *Anais da Sociedade Entomológica do Brasil*, SciELO Brasil, v. 28, n. 4, p. 695–701, 1999.
- GASSOUMI, H. et al. Neural network-based approach for insect classification in cotton ecosystems. In: ICIIT. *International Conference on Intelligent Technologies*. Bangkok, Thailand, 2000. p. 13–15.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. São Paulo, SP: Edgard Blucher, 2000.
- GOODFELLOW, I. et al. *Deep learning*. Cambridge, MA: MIT press, 2016.

- HE, K. et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. Las Vegas, NV: IEEE, 2016. p. 770–778.
- HINTON, G. E. et al. A fast learning algorithm for deep belief nets. *Neural computation*, MIT Press, v. 18, n. 7, p. 1527–1554, 2006.
- HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.
- HOWARD, e. a. J. *The fast.ai deep learning library, lessons, and tutorials*. 2018. <<https://github.com/fastai/fastai,2018>>.
- HSU, T.-H. et al. An interactive flower image recognition system. *Multimedia Tools and Applications*, Springer, v. 53, n. 1, p. 53–73, 2011.
- JI, S. et al. 3d convolutional neural networks for human action recognition. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 35, n. 1, p. 221–231, 2012.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, Elsevier, v. 147, p. 70–90, 2018.
- KARN, U. An intuitive explanation of convolutional neural networks. *the data science blog*, 2016.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- KOTSIANTIS, S. B. et al. Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, v. 160, p. 3–24, 2007.
- KRIZHEVSKY, A. et al. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. Lake Tahoe, NV: ACM, 2012. p. 1097–1105.
- LECUN, Y. et al. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Taipei, Taiwan, v. 86, n. 11, p. 2278–2324, 1998.
- LIM, S. et al. Performance effect analysis for insect classification using convolutional neural network. In: IEEE. *2017 7th IEEE International Conference on Control System, Computing and Engineering (ICCSC)*. Penang, Malaysia, 2017. p. 210–215.
- MARTINEAU, M. et al. A survey on image-based insect classification. *Pattern Recognition*, Elsevier, v. 65, p. 273–284, 2017.
- MIRANDA, J.; SUASSUNA, N. Guia de identificação e controle das principais pragas e doenças do algodoeiro. *Embrapa Algodão-Circular Técnica (INFOTECA-E)*, Campina Grande: Embrapa Algodão, 2004., 2004.
- MONSANTO. Manual of pests 2015. Technology Development, Monsanto Inc., 2015.

- PARKER, J. R. *Algorithms for image processing and computer vision*. Indianapolis, IN: John Wiley & Sons, 2010.
- PASZKE, A. et al. Automatic differentiation in PyTorch. In: NIPS. *NIPS Autodiff Workshop*. Long Beach, California, 2017.
- PEREIRA, M. J. B. et al. Pragas do algodoeiro: identificação, biologia e sintomas de ataque. *Revista Brasileira de Oleaginosas e Fibrosas*, v. 10, n. 3, 2006.
- PLATT, J. Sequential minimal optimization: A fast algorithm for training support vector machines. 1998.
- RAMALHO, F. et al. Distribution of boll weevil (*anthonomus grandis bohemian*) eggs within cotton plants. *Tropical Agriculture, UK*, v. 65, n. 3, p. 245–248, 1988.
- RAWAT, W.; WANG, Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, MIT Press, v. 29, n. 9, p. 2352–2449, 2017.
- SANTURKAR, S. et al. How does batch normalization help optimization? In: NEURAL INFORMATION PROCESSING SYSTEMS FOUNDATION, INC. *Advances in Neural Information Processing Systems*. Rome, Italy, 2018. p. 2483–2493.
- SILVA, C. da et al. Sugestões técnicas para o manejo integrado de pragas do algodoeiro no brasil. *Embrapa Algodão-Circular Técnica (INFOTECA-E)*, Campina Grande: Embrapa Algodão, 2013., 2013.
- SINGH, S. et al. Prediction of breakdown strength of cellulosic insulating materials using artificial neural networks. *Journal of Advanced Dielectrics*, World Scientific, v. 8, n. 01, p. 1850003, 2018.
- WU, J. et al. Enhancing svm active learning for image retrieval using semi-supervised bias-ensemble. In: IEEE. *2010 20th International Conference on Pattern Recognition*. Istanbul, Turkey, 2010. p. 3175–3178.
- XIE, C. et al. Automatic classification for field crop insects via multiple-task sparse representation and multiple-kernel learning. *Computers and Electronics in Agriculture*, Elsevier, v. 119, p. 123–132, 2015.
- XU, R. et al. Aerial images and convolutional neural network for cotton bloom detection. *Frontiers in Plant Science*, Frontiers, v. 8, p. 2235, 2018.

Apêndices

A Exemplos de imagens do banco construído

Este apêndice visa apresentar o mural com 150 amostras de imagens de pragas da cultura do algodão mais 10 imagens da classe de não praga. Pertencem ao conjunto de imagens de treinamento das pragas primárias, as seguintes espécies: *Anthonomus grandis* (A.1b), *Aphis gossypii* (A.1c), *Helicoverpa armigera* (A.1e), *Heliothis virescens* (A.1g), *Pseudoplusia includens* (A.1k) e *Spodoptera frugiperda* (A.1m). Entre as pragas secundárias, estão: *Alabama argillacea* (A.1a), *Bemisia tabaci* (A.1d), *Horcias nobilellus* (A.1i), *Pectinophora gossypiella* (A.1j), *Spodoptera eridania* (A.1l) e *Tetranychus urticae* (A.1o). Por fim, também são apresentadas imagens das fases adultas de *Helicoverpa armigera* (A.1f), *Heliothis virescens* (A.1h) e *Spodoptera frugiperda* (A.1n).



Figura A.1 – Exemplo de imagens de treinamento: a) *Alabama argillacea*, b) *Anthonomus grandis*, c) *Aphis gossypi*, d) *Bemisia tabaci*, e) *Helicoverpa armigera* f) *Helicoverpa armigera* adulta, g) *Heliothis virescens*, h) *Heliothis virescens* adulta, i) *Horcias nobilellus*, j) *Pectinophora gossypiella*, k) *pseudoplusia includens*, l) *Spodoptera eridania*, m) *Spodoptera frugiperda*, n) *Spodoptera frugiperda* adulta, o) *Tetranychus urticae* e n) *Não Praga*.